



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA PODNIKATELSKÁ

FACULTY OF BUSINESS AND MANAGEMENT

ÚSTAV EKONOMIKY

INSTITUTE OF ECONOMICS

**PROGNOSTICKÝ MODEL POPTÁVKY V ODĚVNÍM
PRŮMYSLU**

THE FORECASTING MODEL OF DEMAND IN THE TEXTILE INDUSTRY

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Tomáš Kunc

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Luňáček, Ph.D., MBA

BRNO 2021

Zadání bakalářské práce

Ústav: Ústav ekonomiky
Student: **Tomáš Kunc**
Studijní program: Ekonomika podniku
Studijní obor: bez specializace
Vedoucí práce: **Ing. Jiří Luňáček, Ph.D., MBA**
Akademický rok: 2020/21

Ředitel ústavu Vám v souladu se zákonem č. 111/1998 Sb., o vysokých školách ve znění pozdějších předpisů a se Studijním a zkušebním řádem VUT v Brně zadává bakalářskou práci s názvem:

Prognostický model poptávky v oděvním průmyslu

Charakteristika problematiky úkolu:

Úvod
Cíle práce, metody a postupy zpracování
Teoretická východiska práce
Analýza současného stavu
Vlastní návrhy řešení
Závěr
Seznam použité literatury
Přílohy

Cíle, kterých má být dosaženo:

Cílem práce je tvorba modelu poptávky po oděvech v České republice. Model by měl co nejvěrněji předpovědět situaci na trhu s oděvy pro následující období a zároveň ukázat vývoj situace v průběhu minulých let. Součástí práce je definování faktorů majících vliv na zvolený trh a jejich statistické vyhodnocení.

Základní literární prameny:

HAYASHI, Fumio. Econometrics. Princeton: Princeton University Press, 2000, 683 s. ISBN 0-69-01018-8.

HINDLS, Richard, Stanislava HRONOVÁ, Jan SEGER a Jakub FISCHER. Statistika pro ekonomy. 8. vyd. Praha: Professional Publishing, 2007, 415 s. ISBN 978-80-86946-43-6.

HUŠEK, Roman a Jan PELIKÁN. Aplikovaná ekonometrie: Teorie a praxe. Praha: Professional Publishing, 2003, 263 s. ISBN 80-86419-29-0.

KROPÁČ, Jiří. Statistika B: jednorozměrné a dvourozměrné datové soubory, regresní analýza, časové řady. 2., dopl. vyd. Brno: Vysoké učení technické v Brně, Fakulta podnikatelská, 2009, 151 s. ISBN 978-80-214-3295-6.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2020/21

V Brně dne 28.2.2021

L. S.

prof. Ing. Tomáš Meluzín, Ph.D.
ředitel

doc. Ing. Vojtěch Bartoš, Ph.D.
děkan

ABSTRAKT

Práce se zaměřuje na prognostické metody a jejich porovnání dle ukazatelů přesnosti. Metody byly použity k sestavení prognostického modelu poptávky v oděvním průmyslu. Přínos práce spočívá v určení předpokládané poptávky pro následující období, který mohou využít prodejci, výrobci a všichni, jejichž rozhodování je ovlivněno velikostí poptávky po oděvních výrobcích. Práce obsahuje obecná doporučení, jak postupovat při sestavování prognózy a podle jakých kritérií zvolit vhodnou prognostickou metodu.

KLÍČOVÁ SLOVA

Prognostika, prognostické metody, exponenciální vyhlazování, Holtova metoda, model poptávky

ABSTRACT

Thesis is focused on forecasting methods and their comparison according to accuracy indicators. Forecast methods were utilized for building a forecast model of demand in texture industry. Usefulness of the thesis comes from forecasting an amount of demand in the future, which can be used by sellers, manufacturers and others impacted by amount of demand in textile industry. Thesis contains general recommendations on forecasting process and helps with choice of appropriate methods of forecast.

KEYWORDS

Forecasting, methods of forecast, exponential smoothing, Holt method, model of demand

BIBLIOGRAFICKÁ CITACE

Citace tištěné práce:

KUNC, Tomáš. *Prognostický model poptávky v oděvním průmyslu*. Brno, 2021. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/131904>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav ekonomiky. Vedoucí práce Jiří Luňáček.

Citace elektronického zdroje:

KUNC, Tomáš. *Prognostický model poptávky v oděvním průmyslu* [online]. Brno, 2021 [cit. 2021-05-11]. Dostupné z: <https://www.vutbr.cz/studenti/zav-prace/detail/131904>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta podnikatelská, Ústav ekonomiky. Vedoucí práce Jiří Luňáček.

ČESTNÉ PROHLÁŠENÍ

Prohlašuji, že předložená bakalářská práce je původní a zpracoval jsem ji samostatně. Prohlašuji, že citace použitých pramenů je úplná, že jsem ve své práci neporušil autorská práva (ve smyslu Zákona č. 121/2000 Sb., o právu autorském a o právech souvisejících s právem autorským).

V Brně dne 14. května 2021

.....

podpis autora

PODĚKOVÁNÍ

Děkuji mému vedoucímu Ing. Jiřímu Luňáčkovi Ph.D., MBA za zpětnou vazbu a doporučení, která mi poskytl a s pomocí nichž jsem tvořil bakalářskou práci.

OBSAH

ÚVOD.....	7
1 CÍLE PRÁCE, METODY A POSTUPY ZPRACOVÁNÍ	8
1.1 Cíle práce	8
1.2 Metody a postupy zpracování	8
2 TEORETICKÁ VÝCHODISKA.....	10
2.1 Poptávka.....	10
2.1.1 Zákon poptávky	10
2.1.2 Faktory ovlivňující poptávku.....	11
2.2 Význam prognostiky	13
2.2.1 Předmět prognostiky	13
2.2.2 Fáze prognózování.....	14
2.3 Prognostické metody	18
2.3.1 Kvalitativní metody	18
2.3.2 Kvantitativní metody	19
3 ANALÝZA SOUČASNÉHO STAVU A VLASTNÍ NÁVRHY ŘEŠENÍ.....	26
3.1 Zdroj dat.....	26
3.1.1 Úprava a interpretace datové sady	27
3.1.2 Kategorizace dat	28
3.2 Metody měření přesnosti.....	32
3.3 Výsledky prognostických metod.....	35
3.4 Měření přesnosti metod.....	36
3.5 Porovnání přesnosti a volba metod	40
3.6 Model prognózy poptávky	43
3.7 Slabé stránky řešení.....	45
3.8 Odhad volby vhodné metody	46

3.9	Přínosy práce a doporučení	50
4	ZÁVĚR	53
	SEZNAM POUŽITÝCH ZDROJŮ.....	54
	SEZNAM TABULEK.....	56
	SEZNAM GRAFŮ	57
	SEZNAM OBRÁZKŮ	58
	PŘÍLOHY	59

ÚVOD

Bakalářská práce se zabývá prognózou poptávky v oděvním průmyslu. K sestavení prognózy využiji více než desítku metod predikce a jejich variant, jejichž vzájemným porovnáním odhalím silné a slabé stránky jednotlivých metod a určím nejvhodnější metodu k sestavení modelu poptávky v oděvním průmyslu pro rok 2020.

Metody prognózy se liší v mnoha ohledech a jejich vhodnost závisí na kontextu situace, ve kterém mají být využity. Naštěstí s určením relevantnosti metod prognózy nám pomohou ukazatele přesnosti, počítané odlišnými metodami jejichž specifika také představím v práci.

Práce je rozdělena na dvě hlavní části, teoretická východiska přiblíží problematiku prognózování a metod, které využívá. Představí pravidla a postup žádoucí k učinění co nejkvalitnější možné prognózy. V analýze současného stavu a vlastních návrhů řešení využiji informace uvedené v teoretických východiscích a použiji je k sestavení prognostického modelu poptávky oděvních výrobcích dle skutečných dat zaznamenaných v jednom z produktů Českého statistického úřadu

1 CÍLE PRÁCE, METODY A POSTUPY ZPRACOVÁNÍ

1.1 Cíle práce

Cílem práce je sestavení modelu prognózy poptávky v oděvním průmyslu pro rok 2020 a určení konkrétních přínosů prognózy. Pro úspěšné dosažení cíle práce je třeba definovat a dosáhnout dílčích cílů. Prvním dílčím cílem práce je vymezení pojmů prognostiky, zejména prognostických metod a jejich funkcí, dále také vymezení a definice funkce metod měření přesnosti predikce. Dosažení prvního dílčího cíle zajistí, že mnou použité postupy v praktické části práce budou srozumitelné a jednoznačné.

Druhým dílčím cílem je úprava datové sady a přesný komentář jednotlivých kroků této úpravy. Splnění druhého cíle je nutné vzhledem ke skutečnosti, že vypovídací hodnota dat nalezených pro účely této práce je limitována. Úprava datové sady zajistí, že vypovídací hodnota bude v rámci možností maximalizována.

Třetí dílčí cíl zahrnuje formulace různých variant prognózy tržeb použitím různých metod prognózy a jejich srovnání pomocí ukazatelů přesnosti. Úspěšné splnění třetího dílčího cíle zaručí, že model prognózy poptávky pro rok 2020 bude sestaven na základě metody, která ze všech mnou zkoumaných metod bude vykazovat znaky nejvhodnější metody.

1.2 Metody a postupy zpracování

Práce se skládá ze dvou částí. První část bakalářské práce obsahuje teoretickou rešerši. Zabývá se vymezením pojmů z oblasti prognostiky, včetně kvalitativních a kvantitativních metod prognózy, fází prognózování a metod k určení přesnosti prognózy, vymezení pojmů probíhá na základě informací obsažených ve zdrojích uvedených na konci práce.

Druhá část práce je praktického charakteru. V práci je použita analýza ke zkoumání tržeb oděvního průmyslu jako celku a jeho rozklad na dílčí části reprezentovaných tržbami individuálních druhů výrobků. Analytickým rozkladem zkoumám funkci prognostických metod a metod měření přesnosti, zjišťuji, které vlastnosti různých metod ovlivňují jejich použitelnost v konkrétních situacích a jaké jsou vazby mezi vlastnostmi metod. Použitím syntézy shrnuji klíčové části funkce prognostických metod a ukazatelů přesnosti

k formulaci modelu poptávky. Syntézu aplikuji ke složení jednotlivých částí informací, které jsem získal měřením různých variant prognózy, abych určil doporučení ohledně využití různých metod prognózy, včetně jejich silných a slabých stránek.

Pomocí indukce usuzuji obecné chování jednotlivých metod prognózy, které vyvodím na základě chování mnou pozorované při jejich aplikaci na tržby a ceny široké škály produktů oděvního průmyslu. V práci využívám i její párovou metodu dedukci, pomocí níž zkoumám a ověřuji obecné principy chování metod prognózy a metod měření přesnosti těchto prognóz na konkrétních časových řadách tržeb a cen trhu s oděvy.

2 TEORETICKÁ VÝCHODISKA

V teoretických východiscích se zaměříme na několik oblastí. Nejprve se budeme zabývat poptávkou, následně si představíme prognostiku včetně prognostických metod a způsobu, jakými můžeme měřit přesnost daných metod.

2.1 Poptávka

O tom, co a v jakém množství se bude v tržní ekonomice vyrábět, rozhodují spotřebitelé. Dělají to vytvářením poptávky po daných výrobcích a službách. Pod pojmem poptávka si můžeme představit vztah mezi různými cenami zboží a množstvím, které spotřebitelé chtějí a mohou koupit za danou cenu v určitém časovém období. Tento vztah můžeme znázornit poptávkovou křivkou. Zamýšlené množství, které chtějí spotřebitelé koupit při dané ceně v určitém časovém úseku se nazývá poptávané množství. (Jurečka, 2018, s. 55)

Poptávku můžeme rozdělit na tři hlavní druhy: individuální, tržní a agregátní. V rámci této práce se budeme věnovat především tržní poptávce, tj. poptávka všech spotřebitelů po daném výrobku nebo službě.

2.1.1 Zákon poptávky

„Jednotlivci nebo skupiny budou obecně zvyšovat své nákupy, pokud bude cena klesat, a snižovat své nákupy, když se cena bude zvyšovat. Jinak řečeno: Za jinak neměnných okolností (ceteris paribus), se bude s růstem ceny poptávané množství snižovat a obráceně, při poklesu ceny se bude poptávané množství zvyšovat.

Zákon poptávky platí pro mnoho produktů, ale neplatí pro všechno zboží. V některých případech budou skupiny obyvatelstva s velmi nízkým důchodem nakupovat větší množství produktu s rostoucí cenou, ceteris paribus. Jde o výjimku ze zákona poptávky a taková situace je označována jako Giffenův paradox.“ (Jurečka, 2018, s. 57)

2.1.2 Faktory ovlivňující poptávku

Ceny příbuzných produktů

Když zkoumaný produkt může být nahrazen jinými produkty, pak takové produkty označujeme jako substituty. Substituty jsou produkty spotřebovávané za stejným účelem. Cena substitutů má vliv na poptávku po daném produktu, protože ochota spotřebitelů koupit substituty je ovlivněna změnou relativních cen této skupiny výrobků. S rostoucí cenou substitutu se a po daném výrobku či službě zvyšuje, s poklesem naopak snižuje. Zboží mohou mít i vztah komplementární, takové produkty či služby se ve spotřebě doplňují. (Jurečka, 2018, s. 58)

Důchody spotřebitelů

Závislost důchodu spotřebitele na poptávaném množství produktu může být pozitivní nebo negativní, záleží to na produktu a úrovni důchodu spotřebitele. Pokud se poptávka s rostoucím důchodem spotřebitele zvyšuje a s poklesem důchodu snižuje, hovoříme o normálním zboží. Nicméně poptávka nereaguje na změnu důchodu u všech výrobků či služeb stejně. Pokud při značném zvýšení důchodu vzroste poptávka jen nepatrně anebo při značném snížení důchodu poptávka poklesne pouze nepatrně, hovoříme o nezbytném zboží. Dalším druhem je luxusní zboží, změna poptávky po něm bývá větší než změna samotného důchodu.

Inferiorní zboží je takové, po kterém poptávka roste se snížením důchodu, a naopak klesá se zvýšením důchodu. Nicméně zařazení produktu mezi inferiorní či normální zboží závisí na úrovni důchodu, protože zboží považované jednou skupinou za inferiorní může být pro druhou normální a obráceně. (Jurečka, 2018, s. 59)

Vkus a preference spotřebitelů

Preference spotřebitelů hrají významnou roli při vzniku poptávky po daném produktu. Se zvýšením preference určitého produktu se zvýší množství po něm poptávané. Velkým vlivem na preferenci spotřebitelů reklama, jejíž prostřednictvím firmy ovlivňují preference spotřebitelů, anebo móda, jejíž vliv na preference je také zásadní. (Jurečka, 2018, s. 60)

Počet kupujících a demografická struktura

Při zvýšení počtu kupujících se zvýší poptávka po určitých produktech. Poptávka po některých výrobcích je ovlivněna demografickou strukturou spotřebitelů, např. věkem či pohlavím. (Jurečka, 2018, s. 60)

Očekávání spotřebitelů

Očekávání spotřebitelů mohou souviset s budoucí cenou výrobku, jeho dostupností anebo novým typem produktu. Spotřebitelé mohou zvýšit svou současnou poptávku po produktu na úkor poptávky budoucí či obráceně. Činí tak když očekávají, že se cena či dostupnost v budoucnu změní. (Jurečka, 2018, s. 60)

Specifické faktory

Poptávka po každém produktu bude mít svou vlastní sadu determinantů, které budou odrážet důvody spotřebitelů vedoucí ke koupi daného výrobku. Např. poptávka po zimním oblečení bude závislá na ročním období či počasí. Nebo zavedení zákona o nutnosti používání dětských autosedaček zvedne poptávku po autosedačkách. (Jurečka, 2018, s. 60)

2.2 Význam prognostiky

Prognostika je ve své nejjednodušší definici proces, jehož cílem je předpovědět události, které se uskuteční v budoucnosti a okolnosti, při kterých k tomuto uskutečnění dojde. Přesněji řečeno, snaží se předpovědět změnu v nejisté budoucnosti. (Levenbach, 2016)

Prognostika se dá využít v nepřeberném množství situací, uvedeme následující příklady: Rozhodnutí postavit elektrárnu v příštích pěti letech vyžaduje prognózu poptávky elektřiny. Při plánování rozvržení pracovních sil v call centru uvítáme prognózu objemu hovorů. Prognóza může být určena na několik let dopředu (v případě kapitálových investic) nebo jen několik minut do budoucnosti, například při přesměrovávání hovorů v telekomunikačních sítích. (Hyndman a Athanasopoulos, 2018)

Prognózovatelnost událostí závisí na několika faktorech:

1. jak dobře známe parametry související se situací
2. kolik máme dostupných dat,
3. je naše prognóza ovlivněna skutečností, že danou situaci prognózujeme

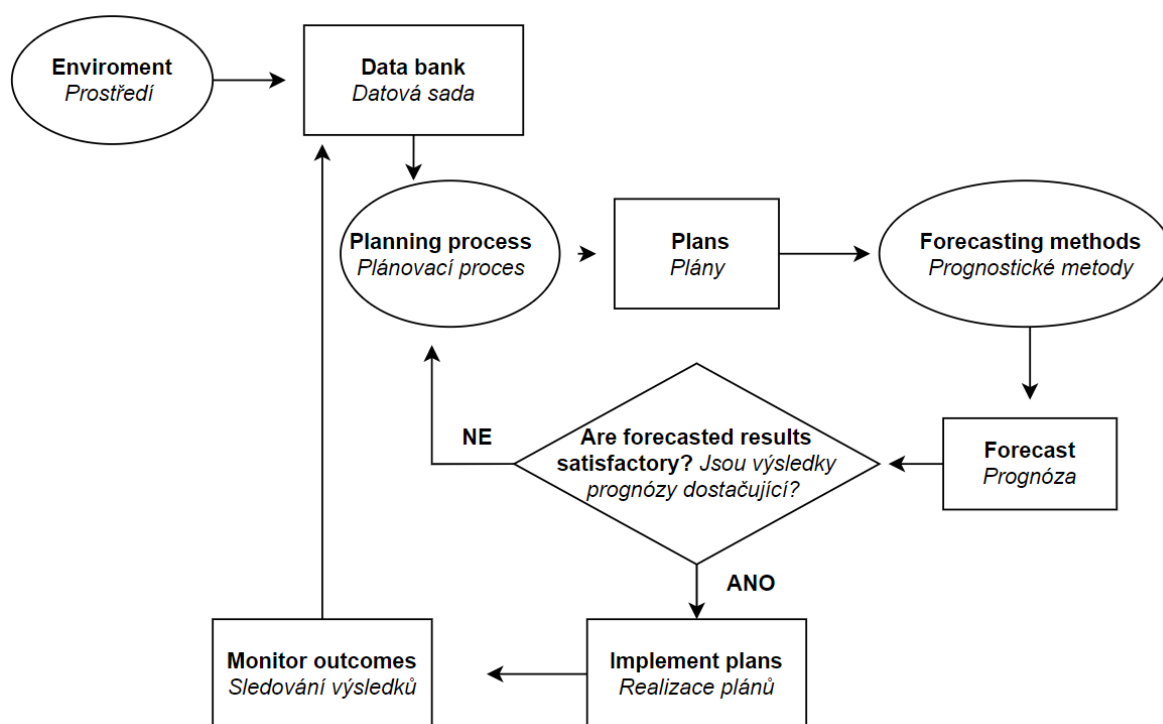
Některé věci jsou lehčí na prognózování než jiné, čas zítřejšího východu slunce lze určit velice přesně, zatímco výherní čísla ve sportce nelze určit vůbec. (Hyndman a Athanasopoulos, 2018)

2.2.1 Předmět prognostiky

Prognostika se zabývá shromažďováním poznatků, zkušeností a představ o budoucnosti, které získáme racionálními postupy nebo logickými úvahami. Prognostika se také věnuje řešení úloh a postupům myšlení o budoucnosti, koriguje intuitivní předpovědi, řeší význam představ o budoucnosti vnímaných jako podklad pro jednání a rozhodování lidí. Prognostika vnímá budoucnost jako objektivně možnou, pravděpodobnou, a ne utopickou. (Buřita, 2003, s. 48)

Lidé často zaměňují prognózování za plánování. Plánování se zabývá otázkou: *jak by svět měl vypadat*, na druhou stranu prognózování odpovídá na otázku: *jak svět bude vypadat*. Schéma níže popisuje vztah mezi prognózou a plánem. Při plánování můžeme využít

prognózk určení výsledků plánů. (Armstrong, 2001, s. 3)



Obrázek 1: Rámec prognózy a plánování.
(Zdroj: Armstrong, 2001, s. 3, vlastní úprava a překlad)

2.2.2 Fáze prognózování

Formulace problémů a stanovení cílů

Formulace problému vyžaduje pochopení, kým a jak bude předpověď použita. Osoba vytvářející prognózu musí komunikovat s lidmi, kteří budou s předpovědí pracovat a se zaměstnanci sbírajícími data, která budou použita k určení prognózy. (Hyndman a Athanasopoulos, 2018)

Sběr informací

V tomto kroku hledáme dva druhy informací. Prvním jsou statistická data a druhým odborná expertíza osob shromažďujících data a zaměstnanců, kteří budou využívat předpověď. Může nastat situace, že data budou zastaralá, v takovém případě budeme upřednostňovat data aktuální. Na druhou stranu dobré statistické modely by měli umět zaznamenat jistou míru změny a neplýtvat daty, která se ještě dají využít. (Hyndman a Athanasopoulos, 2018)

Předběžná analýza

V předběžné analýze je dobré začít grafickým vyobrazením dat. Můžeme zde spatřit opakující se vzorce, významné trendy, sezónnost, znaky svědčící o přítomnosti hospodářského cyklu nebo vyčnívající hodnoty, která potřebují vysvětlení odborníka v oblasti. Zjišťujeme, jaké jsou vztahy mezi proměnnými dostupných k analýze. (Hyndman a Athanasopoulos, 2018)

Volba vhodného modelu a jeho použití

Volba vhodného modelu závisí na dostupnosti historických dat, způsobu využití předpovědi a vztahu proměnných předpovědi. Běžné je vytvoření více potenciálních modelů a jejich vzájemné porovnání. (Hyndman a Athanasopoulos, 2018)

Vyhodnocení přesnosti prognózy

Existuje několik důvodů, proč sledovat přesnost prognózy (predikce). Přesnost se může lišit mezi různými použitými metodami a její změření napoví, jaké metody jsou zrovna nejvhodnější k použití v dané situaci. Přínosnost prognózy může být důkladně určena až po sběru dat za období, které bylo predikováno. (Hyndman a Athanasopoulos, 2018)

Vztah přesnosti predikce s chybě predikce je následující: Přesnost predikce = 1 – chyba predikce. (Sellaiah, 2017)

K určení přesnosti predikce poptávky můžeme použít několik metod:

- Absolutní chyba:

$$e = |D_t - F_t| \quad (2.1)$$

„e“, jež je rozdílem mezi skutečnou poptávkou „D_t“ a plánovanou poptávkou „F_t“.

- Kvadratická chyba:

$$e^2 = (D_t - F_t)^2 \quad (2.2)$$

- Relativní chyba

$$e_r = \frac{|D_t - F_t|}{D_t} \quad (2.3)$$

Tyto tři metody měření přesnosti predikce lze použít, pokud predikce byla provedena jen na jedno období. K měření přesnosti predikce na více období jsou z nich odvozeny další metody, patří mezi ně:

- Střední predikční chyba-MFE (Mean Forecast Error)

$$MFE = \frac{1}{n} \times \sum_{t=1}^n (D_t - F_t) \quad (2.4)$$

Tato metoda ukazuje nepřesnost predikce průměrem sumy rozdílu mezi skutečnou poptávkou a predikcí. Metoda je velmi jednoduchá, ale nezobrazuje skutečnou nepřesnost, výsledek je totiž ovlivněn kladnými i zápornými odchylkami. Tento problém řeší:

- Střední absolutní odchylka – MAD (Mean Absolute Deviation)

$$MAD = \frac{1}{n} \times \sum_{t=1}^n |D_t - F_t| \quad (2.5)$$

Vzorec je totožný až na rozdíl D_t a F_t , který je uveden v absolutní hodnotě. Další metodou je:

- Střední kvadratická odchylka – MSE (Mean Square Error)

$$MSE = \frac{1}{n} \times \sum_{t=1}^n (D_t - F_t)^2 \quad (2.6)$$

Stejně jako MAD i MSE dokáže zamezit vzájemnému vyrušování kladných a záporných odchylek, MSE toto řeší pomocí druhé mocniny. (Novotný, 2013, s. 61)

- Odmocněná střední kvadratická odchylka – RMSE (Root Mean Square Error)

$$RMSE = \sqrt{\frac{1}{n} \times \sum_{t=1}^n (D_t - F_t)^2} \quad (2.7)$$

Metoda RMSE (Root Mean Square Error) představuje odmocninu MSE, čímž je snížen vliv velkých výkyvů, ale zůstává výhoda vzájemného nevyrušení záporných a kladných odchylek:

- Střední absolutní procentní odchylka – MAPE (Mean Absolute Percentage Error)

$$MAPE = \frac{100}{n} \times \sum_{t=1}^n \left| \frac{D_t - F_t}{D_t} \right| \quad (2.8)$$

$$aMAPE = \frac{100}{n} \times \sum_{t=1}^n \frac{|D_t - F_t|}{(D_t + F_t)/2} \quad (2.9)$$

(Urbanec, 2015, s. 48-49)

2.3 Prognostické metody

K prognóze můžeme využít hlavní dva druhy metod, metody kvalitativní a kvantitativní. V následujících kapitolách si představíme nejběžnější kvalitativní metody a poté metody kvantitativní, které využijí v praktické části práce.

2.3.1 Kvalitativní metody

Kvalitativní metody (judgmental), známé také jako subjektivní nebo úvahové, uplatňujeme tehdy, pokud historická data, která se týkají předpovídané události, jsou nedostačující či dokonce nejsou k dispozici vůbec. Kvalitativní metody se používají i v případě, pokud předpovídané události nelze postihnout kvantifikovatelnými informacemi či došlo k velkým, dosud nevídaným změnám. (Buřita, 2003, s. 52)

Přesnost odborného úsudku se zvyšuje s rostoucí znalostí problematiky odborníka. Klíčový je přístup k aktuálním informacím. Výhoda subjektivních metod spočívá v jejich možném rychlém upravení či přizpůsobení změnám a aktuálním informacím. (Hyndman a Athanasopoulos, 2018)

Rozlišujeme 3 hlavní způsoby použití kvalitativních metod

1. Nemáme k dispozici dostatečná data k použití kvantitativních metod a kvalitativní přístup je jedinou možností
2. Máme k dispozici dostatečná data, použijeme kvantitativní metody, které vylepšíme kvalitativním úsudkem.
3. Máme k dispozici dostatečná data, kvantitativní i kvalitativní metody jsou použity nezávisle na sobě a následně zkombinovány.

V případě že máme data k dispozici, je ve většině případů použití kvantitativních dat vhodnější variantou. (Hyndman a Athanasopoulos, 2018)

Delfský panel

Základ Delfské metody stojí na principu: „Víc hlav víc ví.“ Obecně se dá předpokládat, že odborníci mají v problematice různé silné a slabé stránky a kombinací jejich znalostí dosáhneme mnohem lepšího predikčního výsledku. Klíčem Delfské metody je zachovat výhody, které nám přináší predikce ve skupině, ale pokusit se odstranit negativní aspekty skupinové interakce. (Rowe, 2007, s. 11)

Delfský panel je metodou, která má svůj původ v oblasti vojenství při prognózování složitých problémů. Metoda předpokládá zapojení expertů z oblasti tvorby předpovědi. Jsou dotazováni v dialogu či písemné anketě v několika kolech s několikátýdenními intervaly a vyjadřují předpověď hodnotami zvolených parametrů podle předem vydaných instrukcí. V průběhu tvorby předpovědi zůstává každý expert pro ostatní experty anonymní. (Buřita, 2003, s. 53)

Předpověď analogií

Metoda analogie se využívá k prognózování jednoho systému na základě zkoumání jeho podobnosti s charakteristikami jiného systému (reálného či abstraktního). Snažíme se nalézt co nejvíce shodných podstatných vlastností a znaků. Vybíráme je však náhodně, neměli bychom se nechat ovlivnit předčasně utvořeným názorem. U zkoumaných charakteristik je nutno sjednotit jejich obsah a formu. (Buřita, 2003, s. 53)

Tvorba scénářů

Metoda scénářů je velmi odlišná od předchozích. V Delfské a analogické metodě jsme se určit jednu nejpravděpodobnější situaci, u tvorby scénářů určíme situací více, a to i takové, které jsou mnohem méně pravděpodobné. Časté je rozdělování scénářů podle různých kritérií, například na nejlepší variantu, nejhorší variantu, nejpravděpodobnější atd. (Hyndman a Athanasopoulos, 2018)

2.3.2 Kvantitativní metody

Při použití kvantitativních metod aplikujeme statistická data z minulosti v různých časových pohledech. Prognostik s využitím historických dat identifikuje cestu předpovědi, přidá k ní vhodný matematický model a pomocí rovnic modelu předpovídá body v budoucnosti. Takový přístup předpokládá, že identifikovaná cesta pro prognózu pokračuje i do budoucnosti. (Buřita 2003, s. 54)

Průměr

V této metodě se předpověď rovná průměru historických dat. Pokud historická data označíme jako y_1, \dots, y_T , můžeme prognózu napsat jako

$$y_{T+h|T} = \hat{y}_{T+h|T} = \bar{y} = (y_1 + \dots + y_T)/T \quad (2.10)$$

Naivní metoda

Při použití naivní metody je prognózou poslední známá hodnota.


$$\hat{y}_{T+h|T} = y_T \quad (2.11)$$

Sezónní naivní metoda

Podobnou metodu lze použít pro data vykazující vysokou sezónnost. V případě sezónně naivní metody je prognózou naposledy pozorovaná hodnota pro shodné období, např. pro stejný měsíc minulého roku.

$$\hat{y}_{T+h|T} = y_{T+h-m(k+1)} \quad (2.12)$$

Na obrázku níže si porovnáme sezonně naivní metodu s metodou průměru a naivní metodou.




Graf 1: Prognóza produkce piva v Austrálii
(Zdroj: Hyndman a Athanaspoulos, 2018, vlastní úprava a překlad)

Driftová metoda

Variace naivní metody, která umožňuje prognóze zvyšovat či snižovat svou hodnotu v průběhu času, velikost změny v průběhu času je průměrná změna v datech.

$$\hat{y}_{T+h|T} = y_T + \frac{h}{T-1} \sum_{t=2}^T (y_t - y_{t-1}) = y_T + h \left(\frac{y_T - y_1}{T-1} \right) \quad (2.13)$$

Obrázek níže zobrazuje porovnání driftové metody s naivní metodou a metodou průměru.



Graf 2: Vývoj akcii Google z roku 2013

(Zdroj: Hyndman a Athanasopoulos, 2018, vlastní úprava a překlad)

Klouzavý průměr

Určitým zprůměrováním původních pozorování v okolí y_t získáme vyhlazenou hodnotu časové řady v okamžiku t . Můžeme si to představit jako jakési okénko, které klouže podél časové řady, uvnitř kterého se průměruje.

Toto okénko v sobě zahrnuje d členů nalevo od bodu t a d členů napravo od bodu t . Takové okénko má šířku $h = 2d + 1$.

Vyhlazenou hodnotu časové řady v okamžiku t získáme určitým zprůměrováním původních pozorování z jistého okolí pozorování y_t . Můžeme si představit, že podél časové řady klouže okénko, v jehož rámci se průměruje.

Vyhlazenou hodnotu ve středu vyhlazovacího okénka pak zjistíme vztahem:

$$\hat{y}_t = \frac{1}{2d+1} (y_t - d + y_t - d + 1 + \dots + y_{t+d}) \quad (2.14)$$

(Maroš, 2012, s. 264)

Volba délky klouzavé řady není snadná a nelze ji stanovit exaktními statistickými postupy, takže při její volbě postupujeme heuristicky, což představuje snahu o stanovení na základě věcné analýzy zkoumaného jevu. V praxi se většinou setkáme s klouzavými částmi menší délky, např. $h = 2, 3, 4 \dots$, ale lze se samozřejmě setkat i s klouzavými částmi o větším rozsahu. (Hindls, Hronová, Seger a Fischer, 2007, s. 294)

Je možné aplikovat klouzavý průměr na již existující klouzavý průměr. Tato kombinace vyústí ve vážený klouzavý průměr, pomocí kterého můžeme lépe určit trend či cyklus.

(Hyndman a Athanaspoulos, 2018)

Exponenciální vyhlazování

Naivní metoda zmíněná dříve je extrémní případ váženého klouzavého průměru, kdy veškerá váha je přiřazena pouze nejnovějšímu pozorování. Metoda průměru zase přiřazuje všem datům stejnou váhu. V mnoha situacích bychom ale uvítali metodu, která si bere z obou to nejlepší a je takovou zlatou střední cestou. Takovou metodu můžeme popsat jako exponenciální vyhlazování. (Hyndman a Athanaspoulos, 2018)

Prognózy vytvořené pomocí exponenciálního vyhlazování jsou vážené klouzavé průměry, u kterých váha pozorování exponenciálně klesá se stářím pozorování, jinými slovy čím novější data, tím větší důraz je na ně kladen. Jednoduché exponenciální vyhlazování je využitelné u dat, která nemají zřejmý trend nebo sezónnost. (Hyndman a Athanaspoulos, 2018)

Jednoduché exponenciální vyhlazování můžeme zapsat jako:

$$\hat{y}_{T+1|T} = \alpha y_T + \alpha(1-\alpha)y_{T-1} + \alpha(1-\alpha)^2 y_{T-2} + \dots, \quad (2.15)$$

Rychlost klesání váhy s rostoucím stářím dat kontroluje tzv. vyhlazovací parametr α , který nabývá hodnot od 0 do 1. Čím vyšší je α , tím váha dat klesá rychleji. V obrázku níže můžeme vidět, jak rychle klesá váha pozorování y_T pro různé hodnoty α . (Hyndman a Athanaspoulos, 2018)

Tabulka 1: Vliv parametru alfa na váhy pozorování
(Zdroj: Hyndman a Athanasopoulos, 2018)

	$\alpha = 0.2$	$\alpha = 0.4$	$\alpha = 0.6$	$\alpha = 0.8$
y_T	0.2000	0.4000	0.6000	0.8000
y_{T-1}	0.1600	0.2400	0.2400	0.1600
y_{T-2}	0.1280	0.1440	0.0960	0.0320
y_{T-3}	0.1024	0.0864	0.0384	0.0064
y_{T-4}	0.0819	0.0518	0.0154	0.0013
y_{T-5}	0.0655	0.0311	0.0061	0.0003

Holtova metoda

Modifikací exponenciálního vyhlazování využitelnou k predikci dat s trendem je Holtova metoda. Rovnice Holtovy metody v sobě zahrnuje dvě části, první část operující s parametrem α a druhá s parametrem β , který obdobně jako α nabývá hodnot od 0 do 1. Hodnota parametru β odráží trendovost dat, čím je β větší, tím je trend silnější.

$$\hat{y}_{t+h|t} = l_t + hb_t \quad (2.16)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.17)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (2.18)$$

Regresní analýza

Regresní analýza slouží k nalezení trendu v datech, může nám například pomoci najít spojitost mezi hmotností člověka a kalorickým příjmem, regresní analýza nám umožní takovou spojitost kvantifikovat. (Glen, 2021)

Regresní analýzu používáme k poznání a matematickému popisu statistických závislostí a k ověřování deduktivně učiněných teorií. Předmětem jejího zájmu jsou jednostranné závislosti, kdy proti sobě stojí nezávislá proměnná (příčinná, vysvětlující) a závislá proměnná (následková, vysvětlovaná). V takové situaci obvykle zkoumáme obecné tendence ve změnách vysvětlovaných proměnných vzhledem ke změnám vysvětlujících proměnných.

Regresní analýza se snaží najít ideální matematickou funkci, která bude co nejlépe vyjadřovat charakter závislostí a co nejvěrněji zobrazovat průběh změn podmíněných faktorů závisle proměnné. Toto je ve své podstatě hypotetická funkce, kterou nazýváme

jako regresní funkci. Regresní analýza má za cíl co nejlépe přiblížit empirickou regresní funkci a hypotetickou regresní funkci.

$$y_i = \eta_i + \varepsilon_i \quad (2.19)$$

y_i i -tá hodnota vysvětlované proměnné y ,

η_i i -tá hodnota teoretické regresní funkce

ε_i odchylka y_i od η_i

(Pojkarová, 2006, s. 18)

Volba regresní funkce

Při volbě vhodného typu regresní funkce bychom se měli řídit věcně ekonomickými kritérii, tzn. že regresní funkci bychom měli vybrat na základě věcného rozboru vztahů mezi veličinami. Podstatou rozhodnutí by měla být existující ekonomická teorie. Jestliže na základě věcně ekonomických teorií nelze určit vhodný druh regresní funkce, používá se empirický způsob volby grafickou metodou. Formou bodového diagramu se znázorní průběh závislostí, každá dvojice pozorování x a y tvoří jeden bod grafu. Jaký typ regresní funkce by byl pro popis sledované závislosti nejlepší, se rozhoduje podle charakteristického průběhu grafu.

Jako regresní funkce se používají různé matematické funkce (přímka, parabola, logaritmická funkce apod.). Podle tvaru regresní funkce se určujeme různé typy regresních modelů.

- Modely lineární z hlediska parametrů, regresní přímka, regresní hyperbola, regresní logaritmická funkce, regresní parabola
- Modely nelineární, které se transformací dají upravit na lineární tvar z hlediska parametrů, regresní mocninná funkce, regresní exponenciální funkce
- Nelineární modely, které se nedají jednoduše transformovat na lineární tvar

(Pojkarová, 2006, s. 19)

Určení parametrů regresní funkce

Existují různé metody pro odhady parametrů regresní funkce, například metoda nejmenších čtverců, momentová metoda, metoda maximální věrohodnosti,

metoda minimalizace poměru rozptylů nebo dvoustupňová metoda nejmenších čtverců. (Pojkarová, 2006, s. 19)

Jednoduchá lineární regrese

Metoda sloužící k tomu, abychom získali předpis, pomocí kterého budeme schopni předpovědět hodnotu jedné proměnné ze znalosti hodnoty jiné proměnné, pokud mezi těmito dvěma proměnnými existuje příčinná souvislost.

Základem jednoduché lineární regrese je rovnice přímky, která bývá nejčastěji reprezentována předpisem $y = mx + c$ nebo $y = a + bx$. Ve statistice se obvykle používá pro zápis této rovnice předpis obsahující parametry beta:

$$y_t = \beta_0 + \beta_1 x_t + \varepsilon_t \quad (2.20)$$

y: odezva nebo také závislá (vysvětlovaná) proměnná, x: prediktor nebo též nezávislá (vysvětlující) proměnná

Při grafickém znázornění dat vyneseme závislou proměnnou na osu y a nezávislou proměnnou na osu x.

Parametry (koeficienty) β_0 a β_1 jsou neznámé konstanty, β_0 je konstantní člen a udává posunutí přímky po ose y, β_1 je směrnice přímky a určuje sklon přímky. (Math and stats support centre, nedatováno)

3 ANALÝZA SOUČASNÉHO STAVU A VLASTNÍ NÁVRHY ŘEŠENÍ

K části analýzy současného stavu a vlastním návrhům řešení budu v této práci referovat i jako k praktické části. V prvních kapitolách praktické části se seznámíme se zdrojem dat, na která budu aplikovat prognostické metody. Popíšu kroky, které jsem učinil, abych datovou sadu doplnil a umožnil tak její efektivní použití. V dalších částech si ukážeme samotné výsledky různých variant prognózy pro různé metody, určíme jejich přesnost a porovnáme je. V závěru shrnu přínosy praktické části.

3.1 Zdroj dat

V závěrečné práci využiji data publikovaná Českým statistickým úřadem (dále ČSÚ), která ČSÚ zveřejnil v rámci svého produktu „Výroba vybraných výrobků v průmyslu“ dostupného na stránkách ČSÚ. Přesný odkaz je k nalezení v seznamu zdrojů na konci práce.

ČSÚ zde každoročně uvádí tržby za prodej a výrobu různých průmyslových odvětví a konkrétního druhu výrobku za daný rok, a to od roku 2009. Výjimkou není ani oděvní průmysl, z dostupných dat tak mohu čerpat objem prodaného a vyrobeného zboží v ČR v tis. Kč a množství v kusech nejen pro oděvní průmysl jako celek, ale i pro konkrétní druhy výrobků.

Je ovšem nutné zmínit, že sběr dat a jejich následná vypovídací hodnota je od jisté míry limitována. Z informací doprovázejících datovou sadu můžeme vyčíst, že publikace obsahuje výsledky statistiky produkce zjišťované na ročním výkazu Prům 2–01, který vyplňují všechny podniky s převažující průmyslovou činností a s počtem zaměstnanců 20 a více. Zároveň z důvodu ochrany důvěrných dat nemohou být všechny získané údaje uveřejněny.


Z odstavce výše a z letného pohledu na datovou sadu, která nezřídka kdy obsahuje zkratku i.d. (údaj nebylo možno zveřejnit z důvodu ochrany důvěrných dat) je zřejmé, že data v žádném případě neznázorňují bezchybný či vysoce přesný obraz o absolutním množství tržeb, či absolutním množství prodaných kusů v ČR. Dávají nám ale

důvěryhodný přehled o změně množství v čase spolu s průměrnou cenou a její změnou pro různé roky, jelikož k prodejm v tis. Kč uvádí i ČSÚ prodej v kusech.

3.1.1 Úprava a interpretace datové sady

V rámci skutečnosti, že datová sada obsahuje značnou část prázdných míst (25 %), kterou nelze při prognóze jednoduše ignorovat, jsem se rozhodl soubor dat upravit takovým způsobem, který doplní chybějící kritická data a zároveň co nejšetrněji odejme data závažně neúplná, která by modelu prokazovala medvědí službu neboli byla kontraproduktivní.

Obrázek níže ilustruje množství a koncentraci chybějících dat. Červené čtverečky znázorňují data chybějící, zelené jsou data přítomná. Rozdělení celého obrázku do tří částí je pouze z formátovacích důvodů, originálně se jedná o jednu úzkou tabulku o 77 řádcích a 11 sloupcích. Každý sloupec představuje jeden rok, máme tedy 11 sloupců s daty o prodeji pro roky 2009–2019. Každý řádek představuje jeden druh výrobku, např. klobouky, pracujeme tedy s daty pro 77 druhů výrobků oděvního průmyslu.



Obrázek 2: Koncentrace chybějících dat
(Zdroj: Vlastní zpracování)

Je nanejvýš patrné, že chybějící data mají tendenci se shlukovat k sobě. Zjednodušeně řečeno buď ty data k typu výrobku nechybí vůbec, anebo jich chybí opravdu hodně.

Řádků s úplnými daty je 30, alespoň jednu až tři mezery obsahuje 14 typů druhů výrobků a přesně 27 druhů výrobků obsahuje čtyři anebo více mezer.



Graf 3: Členění výrobků dle množství chybějících dat
(Zdroj: Vlastní zpracování)

Rozhodl jsem se v rámci jistého kompromisu pro výpočty odebrat výrobky, kterým chybí údaje pro 4 a více let. Chybějící data u výrobků s 1 až 3 mezerami jsem se rozhodl doplnit. Doplnění jsem provedl tak, abych získal co nejpresnější odhad, ale zároveň nemusel vynakládat nesmyslnou porci úsilí se zanedbatelným přínosem. Data doplním váženým klouzavým průměrem se šířkou okénka 7 a váhami 4, 2, 1, přičemž nejvyšší váhu budou mít data přímo sousedící s odhadovanou hodnotou. Šířka tohoto okénka bude nižší u chybějících dat, která jsou blíže krajním rokům. U krajních chybějících dat ovšem zohledním trend, a to v případě, že tento trend je prokazatelně přítomný v prodejích ostatních let pro daný druh výrobku. Již doplněná data budou mít nulovou váhu a váha originální dána jejich pozicí bude přenesena na další zaznamenanou hodnotu v pořadí, toto hraje roli v případě, kdy původně více chybějících dat bylo vedle sebe či velice blízko u sebe.

Na konci procesu tedy mám objem každoročních tržeb v letech 2009-2019 v Tis. Kč a v kusech pro 50 druhů výrobků, 522 dat bylo zaznamenáno ČSÚ a 28 jsem doplnil odhadem pomocí váženého klouzavého průměru.

3.1.2 Kategorizace dat

V práci se mimo jiné zaměřuji na vyhodnocení přesnosti predikčních metod a jak se tato přesnost změní, pokud se změní povaha dat, která predikci vystavujeme. Jinými slovy zkoumám, jestli se vhodnost různých prognostických metod bude lišit v závislosti na tom,

zdali sestavuji predikci pro trh s oděvy jako celek, nebo jestli predikci určuji pro individuální výrobek (pokaždé když v dalším textu použiji označení výrobek, nemyslím tím konkrétní produkt určité značky nebo firmy, myslím tím skupinu výrobků natolik stejné povahy, že jsou uvedeny ve zdroji od ČSÚ pod totožným ID). Z dostupné datové sady jsem určil několik kategorií, pro které sestavím prognózu a porovnáím výsledky přesnost prognostických metod mezi sebou ale i mezi různými kategoriemi.

V první řadě určím prognózu pro celkové tržby v oděvním průmyslu pro roky 2020 a pro změření přesnosti metody určím i prognózu k možným předcházejícím rokům a tuto prognózu porovnáím se skutečnými zaznamenanými daty. Obdobný postup provedu i pro průměrnou cenu za kus výrobku, učiním tak prognózu ceny pro rok 2020.

Jistým sloučením výrobků jsem vytvořil tři skupiny, tyto skupiny se nazývají Pracovní, Ke spánku a nakonec Bundy + kabáty. Přesné složení výrobků v každé skupině jsem zaznamenal v příloze 1. Všechny tři skupiny tvoří podmnožinu Oděvů celkem, pracovní oblečení dokonce tvoří přibližně polovinu celkových tržeb z oděvů, takže tady předpokládám určitou podobnost vývoje ceny a tržeb. Pro všechny tři skupiny výrobků opět určím prognózu tržeb a cen pro rok 2020.

Nakonec jsem se rozhodl vybrat 3 individuální výrobky a určit prognózu tržeb a cen i pro ně. Těmito výrobky jsou Dámské šaty, Pánské košile, Klobouky a jiné pokrývky hlavy. Přesný název a doplňující informace jsem opět uvedl v příloze 1.

Tabulka 2: Vývoj tržeb a cen
(Zdroj: Vlastní zpracování)

kategorie		2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019
tržby (mil. Kč)	OC	2 165	2 380	2 398	2 356	2 522	2 513	2 892	3 214	3 650	3 431	3 507
	P	696	762	916	870	806	859	1 058	1 065	1 428	1 293	1 352
	BK	133	87	77	64	65	70	67	79	82	78	98
	KS	111	63	47	43	48	27	32	31	31	33	34
	DŠ	56	70	63	54	77	71	78	76	58	57	57
	PK	51	43	40	46	44	36	51	57	60	76	66
	KPH	22	18	57	52	44	44	61	76	62	64	63
cena (Kč/ks)	OC	475	383	397	391	420	414	441	434	463	430	468
	P	433	313	411	365	352	348	387	308	402	326	370
	BK	1 640	1 148	1 565	1 786	1 992	1 835	1 633	1 554	2 950	3 014	2 900
	KS	341	269	269	276	293	289	294	264	324	254	256
	DŠ	410	393	530	373	484	524	542	553	497	479	544
	PK	289	329	346	329	389	374	444	467	449	592	611
	KPH	157	169	220	216	210	223	274	295	264	276	332

Abych určil co nejpresnější prognózu, vyzkouším několik prognostických metod, změřím jejich přesnost a dle výsledků přesnosti zvolím nejvhodnější metodu. Přesnost prognostických metod určím pomocí několika ukazatelů přesnosti, které získám pomocí metod měření přesnosti. Přesnější použití každé metody měření přesnosti upřesním později a také vysvětlím, co představuje metoda WaMAPE, která nebyla představena v teoretické části práce.

Tabulka 3: Použité metody měření přesnosti
(Zdroj: Vlastní zpracování)

metody měření přesnosti
MAD
MSE
RMSE
MAPE
aMAPE
WaMAPE

Tabulky níže shrnují plán mého postupu. Oděvy celkem, každou ze tří skupin výrobků a každý individuální výrobek označuji jedním výrazem kategorie, jedna kategorie tedy představuje jednu časovou řadu. Budu počítat prognózu tržeb pro 7 kategorií, pro identických 7 kategorií budu počítat také prognózu ceny, mým cílem je tedy získat na konci 14 hodnot.

Ke každé kategorii učiním 11 variant prognózy, v každé variantě použiji jinou prognostickou metodu (byť některé varianty mohou mít stejné výsledky), každou variantu poté zhodnotím 6 metodami měření přesnosti prognózy.

Tabulka 4: Zkoumané prognostické metody
(Zdroj: Vlastní zpracování)

prognostická metoda	zkratka metody	souhrnná zkratka
naivní metoda	N, naiv.	
metoda průměru	pr.	
driftová metoda	drift.	
klouzavý průměr	klouz. pr.	
exponenciální vyhlazování s pevně daným parametrem $\alpha = 0,2$	EV 0,2	EV
exponenciální vyhlazování s ideálním α pro MAD	EV MAD	
exponenciální vyhlazování s ideálním α pro MSE	EV MSE	
exponenciální vyhlazování s ideálním α pro WaMAPE	EV WaM	
Holtova metoda s ideálním α a β pro MAD	Holt MAD	Holt.
Holtova metoda s ideálním α a β pro MSE	Holt MSE	
Holtova metoda s ideálním α a β pro WaMAPE	Holt WaM	

Tabulka 5: Kategorie a jejich zkratky
(Zdroj: Vlastní zpracování)

kategorie		zkratka kategorie
tržby	Oděvy celkem	OC
	Pracovní	P
	Bundy a kabáty	BK
	Ke spánku	KS
	Dámské šaty	DŠ
	Pánské košile	PK
	Klobouky a jiné pokrývky hlavy	KPH
cena	Oděvy celkem	OC
	Pracovní	P
	Bundy a kabáty	BK
	Ke spánku	KS
	Dámské šaty	DŠ
	Pánské košile	PK
	Klobouky a jiné pokrývky hlavy	KPH

3.2 Metody měření přesnosti

Pro každou prognózu, u které znám její skutečné zaznamenané hodnoty určím její absolutní chybu, kvadratickou chybu a relativní chybu.

Nejjednodušší metodou měření přesnosti pro více období je metoda střední predikční chyby MFE, její nevýhodou ale je, že se kladné a záporné odchylky navzájem vyrušují. Dojde tak k situaci, že při predikcích, kdy metoda pro některá období předpokládá hodnoty vyšší a pro jiná nižší, než byly skutečné hodnoty, udává menší hodnotu průměru chybovosti, než jsou ve skutečnosti. Tato nevýhoda by v našem případě byla naprosto zásadní, rozhodl jsem se tedy hodnotu MFE neuvádět a nahradit ji střední absolutní odchylkou MAD, která plní stejnou funkci jako MFE, ale není prudce zkreslená přítomností kladných a záporných hodnot zároveň.

Střední absolutní odchylku MAD dokážu určit pomocí absolutní chyby. MAD představuje průměr chyb pro všechny roky prognózy, u kterých dokážu určit absolutní chybu (v našem případě to budou vždy roky 2010 až 2019). Obdobným způsobem spočítám i střední kvadratickou odchylku MSE, jež je průměrem chyb umocněných na druhou pro roky 2010 až 2019. Úzce spojená s MSE je odmocněná střední kvadratická odchylka RMSE, z názvu je zřejmé, že se jedná o odmocněnou hodnotu MSE.

Metody MAD a MSE nám dávají poměrně dobrý obrázek o přesnosti metody prognózy, musíme si ale položit otázku, která metoda je lepší, které můžeme důvěřovat více? Zásadní rozdíl mezi metodami je v tom, nakolik dokážou odchylky ovlivnit celkový průměr v závislosti na tom, jak jsou dané odchylky velké. U metody MAD je vliv odchylky lineárně závislý na její velikosti, u metody MSE je tento vliv exponenciální.

Univerzálně se nedá určit, která metoda měření přesnosti je lepší, vhodnost metody závisí na okolnostech, přesněji řečeno na tom, jakou povahu chyb jsme ochotni tolerovat. Pokud nám zjednodušeně řečeno více vadí málo velkých chyb (například jedna chyba o hodnotě 20 je pro nás v prognóze větší problém, než čtyři chyby o hodnotě 5), pak zvolíme metodu MSE. Pokud nám vysoké výkyvy v přesnosti nevadí, pak můžeme vybrat MAD.

MAD a MSE jsou skvělé k porovnání různých metod prognózy mezi sebou v situaci, že prognózy děláme pro stejná data. Už s nimi ovšem nedokážeme porovnat přesnost prognóz, které jsme vytvořili na základě různých dat (například pro odlišné výrobky).

K vyřešení tohoto problému nám poslouží metoda střední absolutní procentní odchylky MAPE, kterou spočítáme jako průměr podílů mezi absolutní chybou a skutečnou hodnotou. Protože je uvedena v procentech, můžeme s ní jednoduše porovnat různé metody napříč spektrem výrobků a kategorií.

MAPE je velice užitečnou metodou, ale má tendenci více „trestat“ hodnoty predikce vyšší než hodnoty predikce menší. Jak je to možné uvedu na stručném příkladu. Jestliže učiním predikci 10 a skutečná hodnota bude 50, relativní absolutní odchylka (která přímo slouží k výpočtu MAPE) bude $|(10 - 50)| / 50 = 80 \%$. Stejnou hodnotu relativní absolutní odchylky získám, pokud učiním predikci 90 a skutečná hodnota bude stále 50. V prvním případě byla skutečná hodnota pětinasobná mé predikci a případě druhém byla má predikce bezmála jedenkrát tak velká než hodnota skutečná, i přesto je relativní absolutní odchylka u obou případů stejná.

Problém výše řeší metoda upravené střední absolutní procentní odchylky aMAPE, která nám poskytne slušný obrázek o přesnosti prognostické metody a zajistí, že s odchylkami je řádně nakládáno bez ohledu na jejich kladnou či zápornou povahu. Pokud porovnáme hodnotu MAPE a aMAPE, můžeme rychle určit, zda jsme v prognóze v průměru více nadhodnocovali nebo podhodnocovali oproti skutečnosti a o kolik. Pokud je MAPE větší než aMAPE, znamená to, že jsme predikovali hodnoty příliš velké a naopak.


Kvůli povaze dat, s kterými pracuji, aMAPE ještě upravím pro prognostické metody exponenciálního vyhlazování a Holtovy metody, abych získal co nejlepší ukazatel přesnosti prognózy. Specifikem časových řad, s která používám ve své práci je, že mají málo hodnot (pouze 11 hodnot představující prodeje od roku 2009). Z toho důvodu budu pracovat s hodnotou váženého průměru upravených relativních absolutních odchylek (označuji ji jako WaMAPE, ačkoliv jsem se s tímto označením v literatuře nesetkal, ale pro zachování konvence považuji použití zkratky od slova Weighted aMAPE za adekvátní). Váhy distribuji jako počet pozorování snížený o jedna. Rovnici WaMAPE jsem sestavil takto:

$$WaMAPE = \sum_{t=1}^n \left(\frac{|D_t - F_t|}{(D_t + F_t)/2} * w_t \right) * \frac{100}{\sum_{t=1}^n w_t} \quad (3.1)$$

S tím, že w představuje váhu a v mém případě platí $w = t - 1$, protože váha mého pozorování je jeho pořadí snižené o jedna. Například chybě prognózy, kterou jsme učinili na základě pěti pozorování, přidělíme váhu 4. Váha je snížena o jedna z důvodu, že přesnost první prognózy, která je činěna na základě pouze jediného pozorování, je irelevantní bez ohledu na to, kterou metodu prognózy použijí a na kterou kategorii ji aplikují, protože prognóza postavená na základě jediné hodnoty bude znovu ta samá hodnota.

Výpočet WaMAPE nedává u jednoduchých metod prognózy smysl, protože tyto metody nejsou schopny konzistentně zdokonalovat přesnost svých predikcí s rostoucím počtem pozorování. Na druhou stranu metody pokročilejší (exponenciální vyhlazování, Holtova metoda) zpřesní své predikce, pokud jim poskytneme více dat. Pro lepší pochopení kontrastu mezi jednoduchými metodami a pokročilejšími si můžeme pokročilejší metodu představit jako určitou primitivní formu umělé inteligence, která se učí a zlepšuje s rostoucím počtem pozorování.

Abych relevanci a pravdivost výše zmíněného předpokladu podložil daty, přeskočím do budoucna a vypůjčím si výsledky měření přesnosti, kterými se budu zabývat v dalších kapitolách. Z nich jsem spočítal společnou průměrnou hodnotu MAPE napříč všemi kategoriemi pro všechny metody prognózy, u kterých jsem konstatoval, že nejsou schopny konzistentně zlepšovat svou přesnost s rostoucím počtem pozorování (N, pr., drift.). Společnou průměrnou hodnotu MAPE jsem spočítal i napříč všemi kategoriemi pro všechny metody prognózy (EV, Holt.), které jsou schopny zvyšovat svou přesnost s rostoucím počtem pozorování.



Graf 4: Srovnání jednoduchých metod s metodami pokročilejšími v závislosti na počtu pozorování
(Zdroj: Vlastní zpracování)

Mým cílem je určit prognózu na rok 2020, jedná se tedy o období, jehož prognóza bude sestavena na základě 11 pozorování. Jak vyplývá s grafu, metody exponenciálního vyhlazování a Holtova metoda budou mít očekávanou přesnost vyšší pro 11 pozorování než pro nižší počty pozorování, je tedy nanejvýš žádoucí při hodnocení jejich přesnosti za účelem sestavení prognózy s využitím 11 pozorování klást vyšší důraz na odchylky v prognózách s vyšším počtem pozorování. WaMAPE mi zajistí, že pokročilejší metody budou mít prostor využít svůj plný potenciál a nebudou v nevýhodě oproti jednoduchým metodám.

3.3 Výsledky prognostických metod

Prognózy pro všechny kategorie tržeb a ceny pro rok 2020 zobrazuje tabulka níže, v dalších krocích změřím přesnost jednotlivých metod pro dané kategorie a vyberu nejvhodnější metodu prognózy pro každou kategorii. Měření přesnosti vyžaduje určení prognózy pro všechny roky 2009–2019.

Tabulka 6: Prognóza tržeb a cen pro rok 2020

(Zdroj: vlastní zpracování)

kategorie		naivní metoda	metoda průměru	driftová metoda	klouzavý průměr	exp. vyhl. $\alpha = 0,2$
tržby	Oděvy celkem	3 506 766	2 820 746	4 568 214	3 529 289	3 139 860
	Pracovní	1 351 858	1 009 665	1 960 529	1 357 563	1 156 345
	Bundy a kabáty	97 705	81 735	60 100	86 035	81 539
	Ke spánku	33 789	45 448	13 853	32 566	36 688
	Dámské šaty	56 920	65 094	65 921	57 304	63 679
	Pánské košile	66 086	51 848	66 979	67 299	58 229
	Klobouky	62 807	51 058	148 573	63 030	58 781
cena	Oděvy celkem	468	429	423	454	439
	Pracovní	370	365	312	366	360
	Bundy a kabáty	2 900	2 001	3 540	2 955	2 353
	Ke spánku	256	285	213	278	278
	Dámské šaty	544	484	642	507	506
	Pánské košile	611	420	888	551	486
	Klobouky	332	240	507	291	270

Tabulka 7: Prognóza tržeb a cen pro rok 2020 pokročilejšími metodami

(Zdroj: Vlastní zpracování)

kategorie		exp. vyhl. min. MAD	exp. vyhl. min. MSE	exp. vyhl. min. WaMAPE	Holt. m. min. MAD	Holt. m. min. MSE	Holt. m. min. WaMAPE
tržby	OC	3 506 766	3 506 766	3 502 996	3 527 977	3 626 285	3 558 548
	P	1 336 884	1 346 087	1 336 884	1 370 985	1 396 114	1 388 730
	BK	97 705	97 705	95 860	94 502	95 761	89 812
	KS	33 789	33 789	33 468	33 786	33 497	33 391
	DŠ	57 437	58 493	56 920	58 364	64 276	56 759
	PK	66 086	67 030	66 713	68 370	68 839	68 662
	KPH	63 025	63 192	62 895	64 811	66 752	64 811
cena	OC	461	458	460	434	449	454
	P	359	366	365	359	359	359
	BK	2 900	2 900	2 900	2 910	2 852	2 910
	KS	256	256	285	279	282	282
	DŠ	503	516	544	503	519	503
	PK	611	611	611	638	633	642
	KPH	328	332	328	324	329	348

3.4 Měření přesnosti metod

Tabulky v této části zobrazují hodnotu ukazatelů přesnosti pro prognostické metody. Všechny ukazatele jsou určitou formou průměru chyb, tento průměr chyb jsem vždy spočítal z let 2010 až 2019 (roky, ve kterých je možné spočítat rozdíl mezi prognózou a skutečným pozorováním). Pro lepší přehlednost jsem se rozhodl nezahrnout do tabulky všechny ukazatele přesnosti, protože některé ukazatele jsou spolu úzce spojeny a jejich

informační hodnota se překrývá. Například RMSE je druhou odmocninou MSE, není tedy nutné uvádět oba ukazatele, informaci o intenzitě vychylování střední odchylky nám poskytne kterýkoli z nich. Na druhou stranu informační hodnota aMAPE s MAPE a MAD se nepřekrývá kompletně, ale překrytí je stále značné, rozhodl jsem se učinit kompromis a v rámci zjednodušení uvést pouze aMAPE. U exponenciálního vyhlazování a Holtovy metody ještě uvedu i vážený průměr aMAPE neboli WaMAPE. Kompletní tabulky se všemi ukazateli přesnosti jsou v příloze 2A a 2B.

Tabulka 8: Přesnost prognózy naivní metodou, metodou průměru a driftovou metodou
(Zdroj: Vlastní zpracování)

kategorie		naivní m.		m. průměru		driftová m.	
		RMSE	aMAPE	RMSE	aMAPE	RMSE	aMAPE
tržby	Oděvy celkem	238 278	6,49	572 965	16,05	457 824	9,06
	Pracovní	151 743	11,16	267 984	20,71	278 368	17,10
	Bundy a kabáty	17 272	13,55	24 235	22,13	31 683	42,44
	Ke spánku	17 403	18,31	28 684	50,20	21 344	54,08
	Dámské šaty	11 177	13,24	10 541	14,94	17 335	22,37
	Pánské košile	8 597	14,43	12 728	19,64	11 287	18,93
	Klobouky	15 452	23,50	20 315	37,42	56 108	62,23
cena	Oděvy celkem	37	6,53	39	6,96	67	15,47
	Pracovní	71	16,92	50	10,97	87	20,80
	Bundy a kabáty	505	18,30	695	26,26	574	23,83
	Ke spánku	39	9,12	34	9,21	53	17,75
	Dámské šaty	81	13,51	73	13,23	104	16,64
	Pánské košile	57	10,01	113	21,23	92	12,92
	Klobouky	32	10,66	58	21,70	72	20,47

Přesnost naivní metody se velice liší mezi kategoriemi, je úzce spojená se změnou hodnot. Čím více budou hodnoty růst či klesat, tím méně přesnou naivní metoda bude. To můžeme vidět i v ukazatelích středních absolutních procentuálních odchylek, které se u oděvů celkem pohybují u relativně nízké hladiny 6 %, protože hodnoty tržeb a cen oděvů celkem rostly pozvolna, což je očekávané u trhu jako celku. Oproti tomu tržby klobouků, které představují menší trh a jsou náchylnější na vyšší varianci, prošli každoroční změnou přesahující 20 %.

Metoda průměru je horší než metoda naivní ve všech kategoriích, je neúčinná u časových řad s trendem, což je velká část časových řad, s kterými pracuji. Tato metoda se zatím ukazuje jako velmi špatná

Obdobně katastrofální je metoda driftová, což mě trochu překvapuje, driftová metoda je v omezené míře schopna zohlednit trend časové řady, což můžeme vidět u tržeb oděvů celkem, ale je extrémně neúčinná při řadách s nevýrazným trendem a vysokým kolísáním hodnot.

Tabulka 9: Přesnost prognózy metodou klouzavého průměru a EV s $\alpha = 0,2$
(Zdroj: Vlastní zpracování)

kategorie		klouzavý průměr			exp. vyhl. $\alpha = 0,2$		
		RMSE	aMAPE	WaMAPE	RMSE	aMAPE	WaMAPE
tržby	Oděvy celkem	352 778	9,29	10,38	463 149	12,86	16,48
	Pracovní	180 507	13,69	14,45	222 613	17,14	20,83
	Bundy a kabáty	22 644	19,06	12,75	22 485	20,68	14,15
	Ke spánku	22 930	27,29	15,27	24 418	38,29	29,84
	Dámské šaty	10 837	14,28	14,72	10 632	14,95	15,16
	Pánské košile	9 741	15,36	17,07	11 410	17,96	21,80
	Klobouky	16 665	26,22	16,48	17 580	29,11	21,67
cena	Oděvy celkem	38	7,26	5,26	38	6,64	5,11
	Pracovní	51	11,61	10,19	51	11,42	9,36
	Bundy a kabáty	590	23,62	25,25	622	24,22	27,07
	Ke spánku	35	10,40	9,59	33	9,26	8,85
	Dámské šaty	65	12,12	10,35	68	12,37	10,00
	Pánské košile	70	13,23	15,38	93	17,31	21,98
	Klobouky	38	12,65	11,32	47	17,12	18,25

Klouzavý průměr dosahuje lepších výsledků než průměr klasický, bylo by zajímavé sledovat, jak se mění přesnost metody se změnou šířky okénka, které průměruji. V tomto případě průměruji poslední 3 hodnoty, ale dovoluji si tvrdit, že se snížením šířky by klouzavý průměr vykazoval ve většině případů lepší výsledky. Mohu to tvrdit na základě skutečnosti, že naivní metoda je klouzavý průměr se šířkou okénka jedna a metoda naivní dosáhla lepších výsledků než klouzavý průměr v 11 z 14 případů.

Výsledky exponenciálního vyhlazování z pevně daným koeficientem α o hodnotě 0,2 jsou o poznání horší než u naivní metody či klouzavého průměru. Přesnost EV je úzce spojená s nastavením koeficientu α , já ho nastavil příliš nízko a výsledky nejsou příliš dobré. Další varianty EV pracují s optimální hodnotou α , která se častěji pohybuje blíže jedné než nule. Neoptimální nastavení koeficientu má velký vliv na přesnost metody a pokud je koeficient velmi vzdálený optimu, nemá cenu metodu používat.

Tabulka 10: Přesnost podle metody EV s optimálním α pro MAD, MSE a WaMAPE
(Zdroj: Vlastní zpracování)

kategorie		EV min. MAD		EV min. MSE		EV min. WaMAPE	
		aMAPE	α	RMSE	α	WaMAPE	α
tržby	Oděvy celkem	6,49	1,00	238 278	1,00	7,04	0,94
	Pracovní	10,64	0,71	150 162	0,88	10,57	0,71
	Bundy a kabáty	13,55	1,00	17 272	1,00	10,71	0,90
	Ke spánku	18,31	1,00	17 403	1,00	8,69	0,79
	Dámské šaty	12,61	0,72	10 533	0,58	9,95	1,00
	Pánské košile	14,43	1,00	8 533	0,87	15,37	0,92
	Klobouky	21,91	0,85	15 183	0,75	12,97	0,42
cena	Oděvy celkem	5,66	0,78	35	0,65	4,69	0,74
	Pracovní	11,78	0,34	54	0,20	8,70	0,00
	Bundy a kabáty	18,30	1,00	505	1,00	15,49	1,00
	Ke spánku	8,98	0,98	39	1,00	8,67	0,00
	Dámské šaty	12,36	0,17	67	0,37	10,12	1,00
	Pánské košile	10,01	1,00	57	0,97	10,49	1,00
	Klobouky	10,57	0,92	32	1,00	10,90	0,92

Exponenciální vyhlazování s optimálním koeficientem je doposud nejpřesnější metoda, což není překvapující vzhledem k faktu, že se zákonitě jedná o variantu exponenciálního vyrovnávání s nejlépe nastaveným koeficientem α a její sestavení je řádově pracnější než sestavení EV s jednotným koeficientem. Ale i tato metoda má své limity, neumí zohlednit trend časové řady, což můžeme vidět v případech, kdy se α rovná jedné. V takovém případě je totiž EV totožná s naivní metodou a metoda tak přikládá veškerou váhu na poslední pozorování, což je vidět například u tržeb EV MAD pro oblečení celkem.

Tabulka 11: Přesnost Holt. m. pro optimální koeficienty MAD, MSE a WaMAPE
(Zdroj: Vlastní zpracování)


kategorie		Holtova m. min. MAD			Holtova m. min. MSE			Holtova m. min. WaMAPE		
		aMAPE	α	β	RMSE	α	β	WaMAPE	α	β
tržby	OC	6,37	0,52	0,73	219 655	0,97	0,00	6,42	0,91	0,58
	P	9,96	0,55	0,00	140 625	0,72	0,00	9,31	0,65	0,00
	BK	12,02	0,42	1,00	16 636	0,50	0,79	10,35	0,38	0,55
	KS	14,79	0,50	0,98	16 562	0,49	0,73	7,72	0,42	0,75
	DŠ	13,60	0,37	0,76	10 633	0,00	1,00	10,06	0,52	0,99
	PK	14,72	0,89	0,00	8 509	0,52	0,67	15,09	0,71	0,65
	KPH	22,65	0,30	0,00	15 180	0,44	0,00	12,87	0,30	0,00
cena	OC	5,84	0,04	0,70	36	0,25	0,70	4,81	0,31	0,79
	P	11,00	0,00	0,00	52	0,00	0,00	8,60	0,00	0,00
	BK	19,42	0,52	1,00	514	0,43	1,00	15,53	0,52	1,00
	KS	7,85	0,05	0,90	32	0,00	0,82	8,51	0,00	0,83
	DŠ	12,35	0,09	0,00	68	0,25	0,00	9,79	0,09	0,00
	PK	8,99	0,93	0,00	50	0,79	0,07	9,09	0,89	0,11
	KPH	9,74	0,62	0,00	30	0,70	0,00	9,22	0,99	0,00

Holtova metoda je dle teorie metoda exponenciálního vyhlazování obohacená o schopnost při prognóze zohlednit trend časové řady. Její nejlepší výsledky ze všech zde představených metod ve většině kategorií dávají teorii za pravdu. Při prognóze časové řady se zřejmým trendem je jednoznačně nejlepší metodou, a u časových řad se slabším či neprokazatelným trendem a intenzivním kolísáním odchylek stále patří mezi ty lepší v tomto dokumentu představené metody. Je to z důvodu, že data, která postrádají trend a vykazují vysoké kolísání odchylky představují problém pro všechny mnou představené metody, nejen pro Holtovu.


3.5 Porovnání přesnosti a volba metod

Dalším krokem je porovnat metody prognózy dle ukazatelů přesnosti a vybrat nejlepší prognostickou metodu pro každou kategorii. Součástí rozhodování o výběru vhodné metody je pochopení kontextu prognózy, určitou roli hraje subjektivní posouzení důležitosti a relevance jednotlivých ukazatelů přesnosti. Ukázkové relativní srovnání metod prognózy dle ukazatelů přesnosti můžeme vidět níže. Jedná se o prognózu kategorie tržeb oděvů celkem, 100 % představuje základ nejhorší metody, tou je v případě všech ukazatelů metoda průměru. Například hodnota 50 % tak znamená, že odchylka

prognostické metody je poloviční oproti nejhorší metodě (v našem případě vždy metoda průměru).



Graf 5: Srovnání metod prognózy tržeb oděvů celkem dle ukazatelů MAD, MSE, RMSE
(Zdroj: Vlastní zpracování)



Graf 6: Srovnání metod prognózy tržeb oděvů celkem dle MAPE, aMAPE, WaMAPE
(Zdroj: Vlastní zpracování)

Metoda průměru je jednoznačně nejhorší, druhá nejméně přesná metoda je exponenciální vyhlazování s pevně daným koeficientem alfa na hodnotě 0,2. Tato nepřesnost je zaviněna příliš nízkou nastaveným koeficientem, ideální koeficient alfa se většinou pohyboval blíže hodnoty jedna než nule.

Možná až překvapivě dobrých výsledků dosahuje naivní metoda, velice dobře si vede i exponenciální vyhlazování a Holtova metoda. Kompletní seznam metod s nejvyšší

přesností v rámci všech kategorií pro každý ukazatel přesnosti ilustruje následující tabulka. Lomítko znamená, že metody sdílejí stejné výsledky přesnosti.

Tabulka 12: Metody vykazující nejvyšší přesnost dle kategorie a ukazatele přesnosti
(Zdroj: Vlastní zpracování)

kategorie		ukazatel přesnosti					
		MAD	MAPE	aMAPE	MSE	RMSE	WaMAPE
tržby	Oděvy celkem	Holt MAD	N / EV MAD / EV MSE	Holt MAD	Holt MSE	Holt MSE	Holt WaM
	Pracovní	Holt MAD	EV MAD	Holt MAD	Holt MSE	Holt MSE	Holt WaM
	Bundy a kabáty	Holt MAD	Holt MAD	Holt MAD	Holt MSE	Holt MSE	Holt WaM
	Ke spánku	Holt MAD	Holt MAD	Holt MAD	Holt MSE	Holt MSE	Holt WaM
	Dámské šaty	EV MAD	EV MAD	EV MAD	EV MSE	EV MSE	N
	Pánské košile	Holt MAD	N	H. MAD / H. WaM	Holt MSE	Holt MSE	Holt WaM
	Klobouky	EV MAD	EV WaM	EV MAD	Holt MSE	Holt MSE	Holt WaM
cena	Oděvy celkem	EV MAD	EV MAD	EV MAD	EV MSE	EV MSE	EV WaM
	Pracovní	Holt MAD	holt MAD	EV WaM / pr	Průměr	Průměr	Holt MAD
	Bundy a kabáty	N / EV / holt MAD	N / EV MAD	EV WaM / EV MAD	N / EV MAD / EV MSE	N / EV MAD / EV MSE	N
	Ke spánku	Holt MAD	holt MAD	Holt MAD	Holt MSE	Holt MSE	Holt WaM
	Dámské šaty	klouz. pr.	EV MAD	klouz pr.	exp MSE	EV MSE	H. MAD / H. WaM
	Pánské košile	Holt MAD	EV MAD	Holt MAD	Holt MSE	Holt MSE	H. MAD / H. WaM
	Klobouky	Holt MAD	EV MAD	Holt MAD	Holt MSE	Holt MSE	Holt WaM

Rozhodující ukazatel, dle kterého vyberu nejvhodnější metodu, bude pro exponenciální vyhlazování a Holtovu metodu WaMAPE, tento ukazatel je dle mého mínění nejlepším ukazatelem přesnosti těchto dvou metod z důvodu, které jsem popsal při představování WaMAPE. U zbývajících metod budu klást největší důraz na aMAPE. Pokud bude více metod dosahovat stejných výsledků, vyberu méně pracnou metodu. Kompletní výběr nejvhodnějších metod pro všechny kategorie spolu s konkrétní hodnotou prognózy tržeb a ceny můžeme vidět v tabulce níže.

Tabulka 13: Zvolená prognóza pro rok 2020
(Zdroj: Vlastní zpracování)

kategorie		metoda	2020
tržby	Oděvy celkem	Holt WaM	3 558 548
	Pracovní	Holt WaM	1 388 730
	Bundy a kabáty	Holt WaM	89 812
	Ke spánku	Holt WaM	33 391
	Dámské šaty	EV MAD	57 437
	Pánské košile	Holt WaM	68 662
	Klobouky	Holt WaM	64 811
cena	Oděvy celkem	EV WaM	460
	Pracovní	Holt MAD	359
	Bundy a kabáty	Naivní	2 900
	Ke spánku	Holt WaM	282
	Dámské šaty	Holt WaM	503
	Pánské košile	Holt WaM	642
	Klobouky	Holt WaM	348


3.6 Model prognózy poptávky

Další tabulka ukazuje hodnotu prognózy v kontextu skutečných prodejů a cen posledních několika let.

Tabulka 14: Vývoj tržeb a průměrné ceny včetně prognózy pro rok 2020
(Zdroj: Vlastní zpracování)


kategorie		2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
tržby (mil. Kč)	OC	2 165	2 380	2 398	2 356	2 522	2 513	2 892	3 214	3 650	3 431	3 507	3 559
	P	696	762	916	870	806	859	1 058	1 065	1 428	1 293	1 352	1 389
	BK	133	87	77	64	65	70	67	79	82	78	98	90
	KS	111	63	47	43	48	27	32	31	31	33	34	33
	DŠ	56	70	63	54	77	71	78	76	58	57	57	57
	PK	51	43	40	46	44	36	51	57	60	76	66	69
	KPH	22	18	57	52	44	44	61	76	62	64	63	65
cena (Kč/ks)	OC	475	383	397	391	420	414	441	434	463	430	468	460
	P	433	313	411	365	352	348	387	308	402	326	370	359
	BK	1 640	1 148	1 565	1 786	1 992	1 835	1 633	1 554	2 950	3 014	2 900	2 900
	KS	341	269	269	276	293	289	294	264	324	254	256	282
	DŠ	410	393	530	373	484	524	542	553	497	479	544	503
	PK	289	329	346	329	389	374	444	467	449	592	611	642
	KPH	157	169	220	216	210	223	274	295	264	276	332	348

U oděvů celkem očekáváme nárůst tržeb oproti roku 2019 o 1,5 %, prognóza ceny ale klesá předpokládá pokles ceny v průměru o 8 Kč za kus. Pokud by se prognóza naplnila, zákonitě by muselo dojít ke zvýšení objemu prodaného zboží o 1,75 %. Vývoj tržeb oděvů celkem a prognózu pro následující období ilustruje graf níže.



Graf 7: Vývoj tržeb oděvů celkem včetně prognózy pro rok 2020
(Zdroj: Vlastní zpracování)

Mírný nárůst tržeb předpokládáme i pro pánské košile a klobouků, na druhou stranu pokles očekáváme u bund a kabátů a oblečení určenému ke spánku, zejména nočních košil a pyžam.




Graf 8: Vývoj průměrné ceny oděvů celkem včetně prognózy pro rok 2020
(Zdroj: Vlastní zpracování)

Pokles ceny předpokládáme u pracovního oblečení a dámských šatů, nárůst ceny u pánských košil, klobouků a jiných pokrývek hlavy a oblečení určenému ke spánku. U ceny oděvů celkem očekáváme mírný pokles oproti roku 2019, křivka má zajímavý

průběh kdy každým rokem střídá pokles a nárůst, ale nárůst v posledních letech převyšuje nad poklesem a celkový trend tak má spíše růstový charakter.

3.7 Slabé stránky řešení

Pro tržby oděvů celkem jsem se rozhodl aplikovat jednoduchou lineární regresi, jejíž vysvětlující proměnná je čas, abych lépe demonstroval možnou slabou stránku mého řešení. Křivku trendu, kterou popisuje rovnice $y = 152\,313x + 1\,906\,866$ můžeme vidět znázorněnou v grafu níže. Hodnota prognózy tržeb pro rok 2020 vyšla 3 734 622 tis. Kč., s horní hranicí intervalu pro hladinu spolehlivosti 95 % v hodnotě 3 776 655 a se spodní hranicí spolehlivosti 95 % v hodnotě 3 692 590. Modrá křivka znázorňuje zaznamenané tržby oděvů celkem pro roky 2009 až 2019. Přerušovaná křivka je rovnice lineární regrese, její pokračování překračující zaznamenané tržby (roky 2020 a dále) nám určuje prognózu lineární regrese v dalších obdobích.



Graf 9: Křivka lineární regrese pro tržby oděvů celkem
(Zdroj: Vlastní zpracování)

Zmíněná slabina je patrná už při porovnání Holtovy metody, exponenciálního vyhlazování a naivní metody. Nicméně při zařazení lineární regrese je slabá stránka ještě výraznější. Slabinu vysvětlím pomocí přehledu výsledků prognózy oděvů celkem a jejich přesnost pro nejpřesnější metody prognózy.

Tabulka 15: Porovnání přesnosti a hodnoty prognózy 2020
(Zdroj: Vlastní zpracování)

	MAD	RMSE	aMAPE	WaMAPE	prognóza 2020	Odchylka prognózy od Holt. metody
Naivní	188 432	238 278	6,49	7,07	3 506 766	1,48%
EV	188 432	238 278	6,49	7,04	3 502 996	1,59%
Holt.	183 729	219 655	6,37	6,42	3 558 548	
Lin. reg.	207 986	257 615	7,30	7,07	3 734 622	4,95%

Ačkoli všechny čtyři metody mají velice podobné hodnoty přesnosti, zejména, pokud se bavíme o procentuálních ukazatelích aMAPE a WaMAPE, kde je rozdíl mezi Holtovou metodou a zbytkem lehce přes půl procentního bodu, samotný rozdíl v hodnotě prognózy je mnohem větší. Prognóza pomocí naivní metody a EV předpokládá tržby menší o více než 50 000 tis., což představuje relativní odchylku od prognózy Holtovou metodou o přibližně 1,5 %. Přesnost prognózy lineární regrese je také horší jen o necelý procentní bod, ale samotná prognóza předpokládá tržby vyšší o bezmála 200 000 tis. Kč, což představuje odchylku od Holtovy metody o necelých 5 %.

Použitím selského rozumu by člověk očekával, že metody mající podobnou přesnost budou předpokládat podobné hodnoty prognózy, ale není tomu tak. Slabou stránkou tedy je, že mé řešení neukazuje, jak se rozhodnout v situaci, kdy jedna metoda má sice nejvyšší ukazatele přesnosti, ale její hodnota prognózy se zásadně odlišuje od metod méně přesných, kterých je ale více a které ukazují podobné hodnoty prognózy. Jednoduše řečeno tak přichází dilema, zdali se spolehnout na kvalitu jedné metody či kvantitu více metod, které ukazují podobnou hodnotu prognózy. Problém by mohla vyřešit nějaká pokročilejší metoda, která dokáže zhodnotit výsledky více metod a ukázat nám, které metodě můžeme více důvěřovat. Zkoumání takové metody už je ovšem mimo pole působnosti mé bakalářské práce.

3.8 Odhad volby vhodné metody

Klíčovou schopností při sestavování prognózy, která nám dokáže ušetřit spoustu času a energie, je schopnost poznat, která metoda bude efektivní a naopak, kterou metodu bychom aplikovali zbytečně. Tato schopnost je o to cennější v případě, kdy potřebujeme sestavit prognózu ve velmi omezeném čase, anebo se nám nevyplatí vynakládat příliš mnoho zdrojů do zkoumání, jaká metoda bude vhodná, například v situacích, kdy se spokojíme i s jednodušší prognózou, u které není naprostá přesnost vyžadována.

Jaká metoda prognózy bude účinná můžeme posoudit na základě předpokladu, který si vybudujeme z pozorovaných hodnot, a ještě v lepším případě z jejich grafického znázornění pomocí grafu. Zaměřujeme se na vlastnosti křivky, zajímá nás trend a kolísání hodnot. Dle teorie ohledně funkce jednotlivých metod prognózy můžeme stanovit několik pomůcek, které by nám měly napovědět, zdali a které metody budou účinné či nikoli.

Naivní metoda je zcela závislá na kolísání hodnot, čím bude kolísání (střední odchylka) větší, tím bude naivní metoda méně přesná. Vyšší střední odchylka má obecně negativní vliv na všechny mnou zkoumané metody, ale na naivní metodu má dopad větší než u ostatních metod. Metoda průměru funguje pouze u křivky bez trendu s nízkou střední odchylkou, takových křivek ale reálně bude minimum, průměru chybí flexibilita ostatních metod a použitelnost je tak velmi vzácná.

Driftovou metodu zvolíme, pokud chceme využít její jednoduchost a zároveň data mají trend s minimálním kolísáním hodnot. Bohužel i velmi malé kolísání v hodnotách dokáže udělat z driftové metody špatnou volbu, protože tato metoda je velmi citlivá na kolísání hodnot a na změnu trendu. Kvůli této citlivosti dosahovala driftová metoda velice špatných výsledků téměř u všech mnou zkoumaných časových řad.

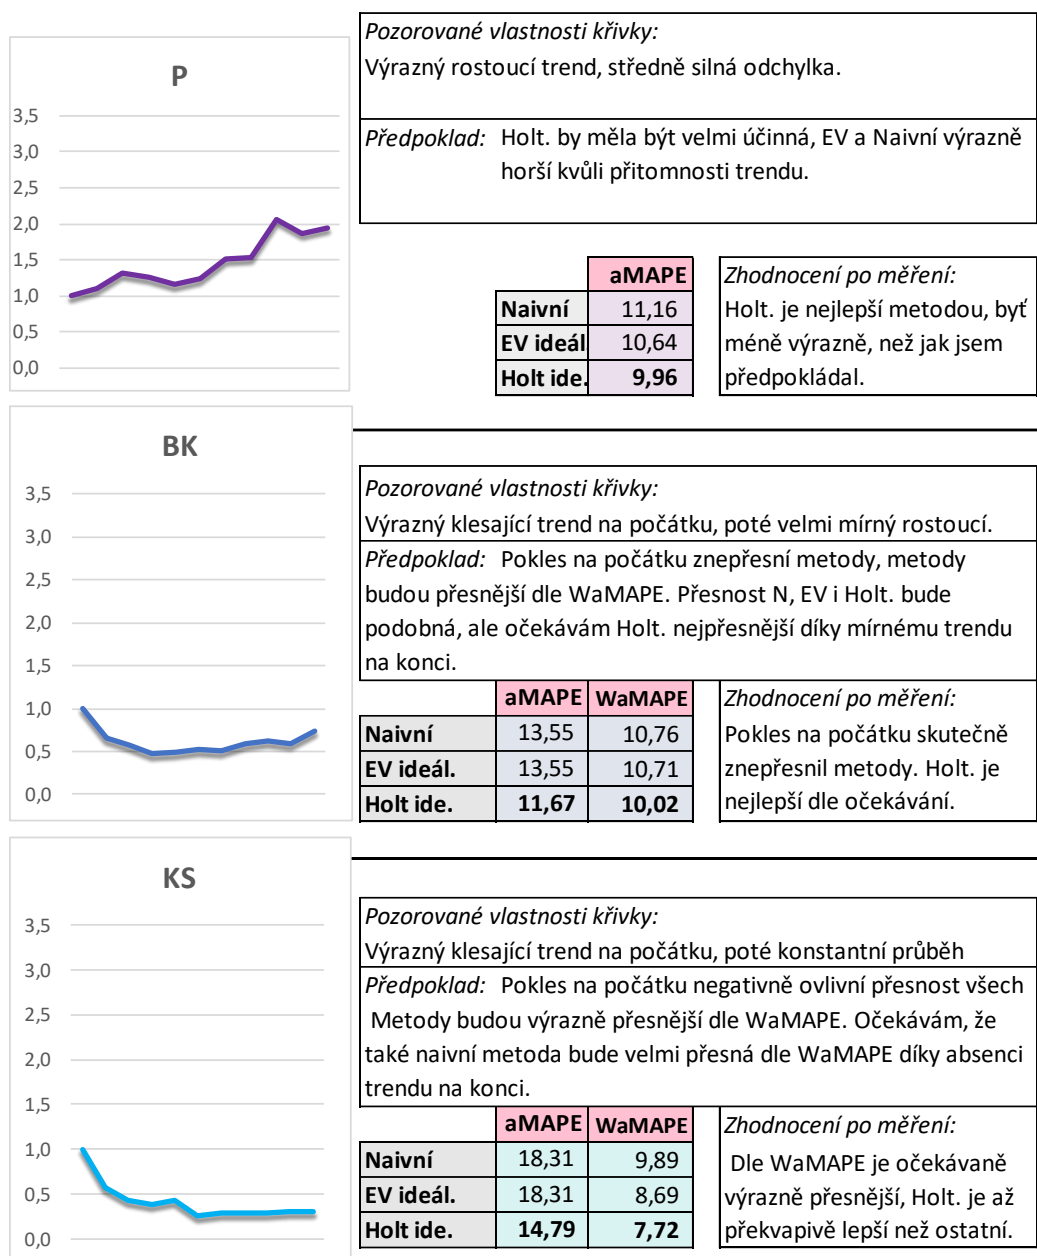
Klouzavý průměr je vylepšenou verzí metody průměru, v porovnání s průměrem lépe obstojí u křivek s trendem, jedná se o kompromis mezi pracností a výsledky. Je o trochu pracnější na spočítání než jednoduchý průměr, ale neposkytuje opravdu nepřesné výsledky tak často jako metoda průměru. Na druhou stranu tato metoda je více pracná než metoda naivní, ale naivní metoda dosáhla lepších výsledků ve více případech než klouzavý průměr, klouzavý průměr tedy využijeme ve velmi specifických případech.

Exponenciální vyhlazování je o řád pracnější než předchozí metody, zejména pokud dopočítáváme ideální alfa, ale poskytuje velmi dobré výsledky v mnoha případech, nejvíce pokud křivka nemá jeden výrazný trend, ale vidíme mezi hodnotami návaznost na sebe (např. křivka chvíli mírně roste, poté zase mírně klesá atd.) Pokud tato návaznost v hodnotách chybí, z exponenciálního vyhlazování s ideálním alfa se stává naivní metoda a použití exponenciálního vyhlazování tak není vůbec efektivní.

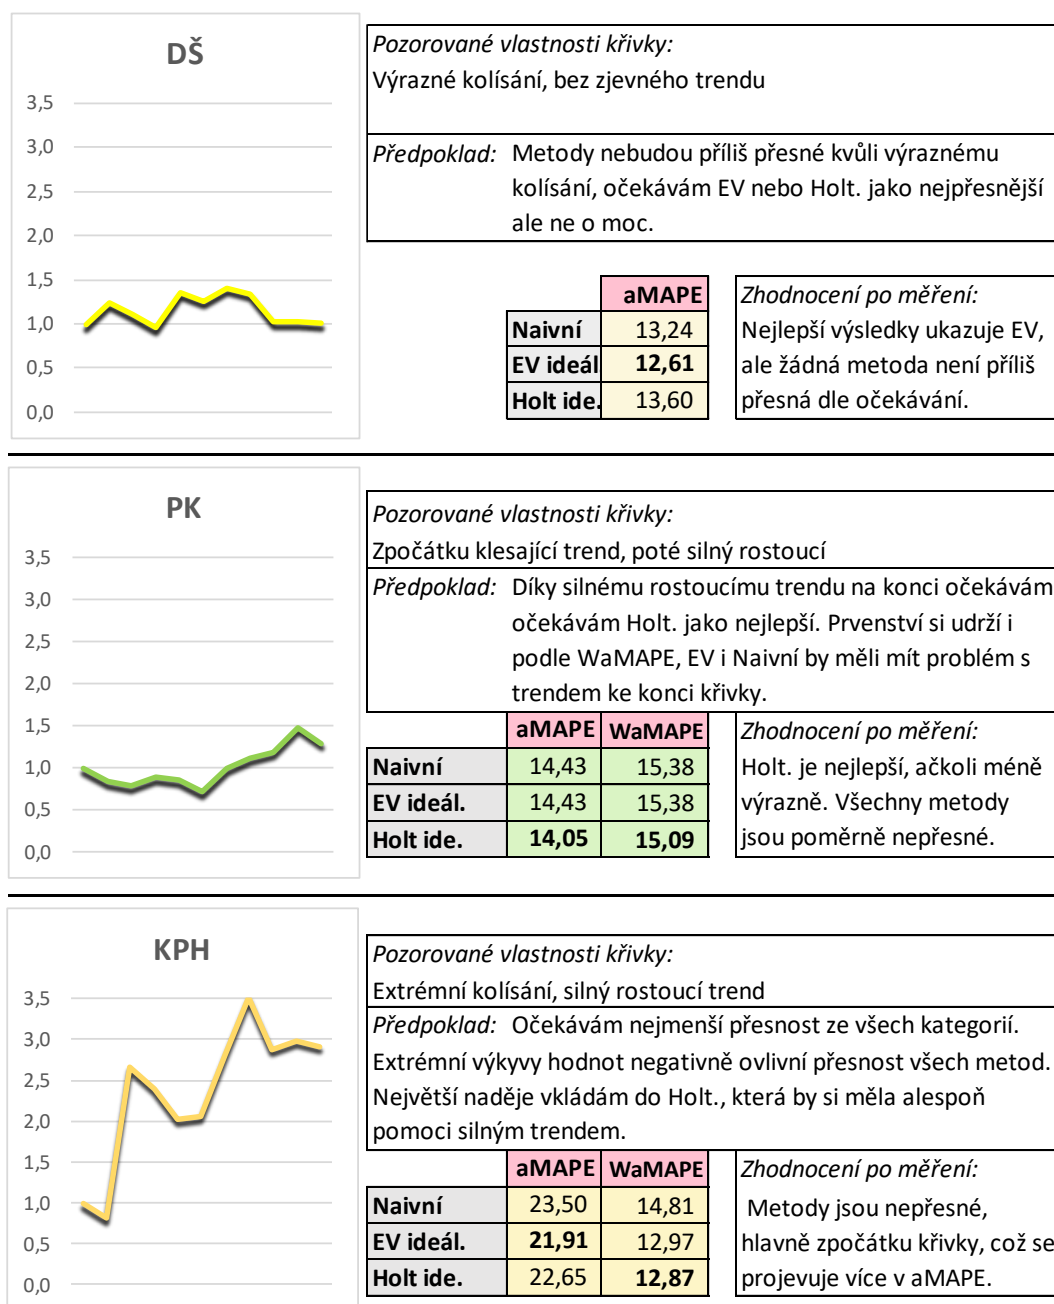
Holtova metoda je nejlepší volbou ve většině případů, ale jedná se o nejpracnější metodu. Její využití vidím v datech s trendem a zjevným kolísáním hodnot, kvůli kterému by ostatní metody byly nepřesné.

Poznatky popsané výše jsem se rozhodl otestovat na hodnotách tržeb pro kategorie zkoumané v této práci. Než jsem spočítal přesnost jednotlivých metod, napsal jsem předpoklad ke každé kategorii, předpoklad jsem určil na základě pozorovaných vlastností křivky a poznatků použitelnosti každé metody. V každém předpokladu jsem určil očekávání, jaká mám v jednotlivých metodách a které metody očekávám, že budou fungovat nejlépe. Také jsem odhadl, jak moc je přesnost metod ovlivněna počátkem křivky, a tedy jestli nevyjde přesněji ukazatel WaMAPE namísto aMAPE.

Poté jsem změřil přesnost jednotlivých metod a zhodnotil, nakolik se můj předpoklad naplnil. Všechny předpoklady a jejich zhodnocení jsem sepsal do dvou souhrnů níže. Stupnice vlevo každého grafu je relativní hodnota tržeb oproti tržbám prvního zaznamenaného roku (2009). Pokud tedy graf ukazuje hodnotu 1,7 znamená to, že hodnota tržeb je v daném roce 170 % hodnoty tržeb roku 2009. Nejlepší metodu se mi podařilo odhadnout ve všech případech, což není příliš překvapivé, protože Holtova metoda je ze všech mnou popsaných metod nejkompexnější a poskytuje nejlepší výsledky v drtivé většině případů. V čem se můj odhad liší od skutečnosti je míra toho, nakolik lepší daná předpokládaná nejlepší metoda je oproti ostatním metodám.



Obrázek 3: Předpoklad vhodnosti metod dle vlastností křivky
(Zdroj: Vlastní zpracování)



Obrázek 4: Druhá část předpokladu vhodnosti metod dle vlastností křivky
(Zdroj: vlastní zpracování)

3.9 Přínosy práce a doporučení

Přínosy bakalářské práce bych rozdělil do tří skupin. První skupinou jsou přínosy spojené s hodnotou prognózy pro rok 2020. Předpokládanou poptávku po produktech oděvního průmyslu, a především její trend, tzn. jestli můžeme očekávat její růst či pokles, ocení

prodejci oděvů, výrobci, přepravci a další subjekty, jejich činnost či rozhodování je ovlivněno množstvím poptávaného oděvu.

Je patrné, že prognózu jsem dělal pro rok 2020, protože v době tvorby této práce se jednalo o nejaktuálnější data, nicméně lze argumentovat, že využitelnost takové prognózy je značně limitována, protože její aktuálnost velmi rychle klesá. Zde bych rád navázal druhou skupinou přínosů, a to je prognóza pro další období 2021. Je možné obětovat určitou část přesnosti prognózy, abychom získali předpoklad tržeb pro období 2021. Jak velkou část mám na mysli ukazuje tabulka níže, jsou v ní spočítány ukazatele přesnosti pro situaci, kdy metoda nečiní prognózu na jedno následující období, ale na dvě období dopředu.

Tabulka 16: Ukazatele přesnosti prognózy pro rok 2021
(Zdroj: Vlastní zpracování)

metoda	prognóza 2021	MAD	MSE	RMSE	MAPE	aMAPE	WaMAPE
Naivní	3 506 766	302 979	151 815 467 899	389 635	9,74	10,51	11,79
EV	3 506 766	302 979	151 815 467 899	389 635	9,74	10,51	11,79
Holt.	3 560 845	261 121	114 655 006 922	338 607	8,56	8,99	10,32

Zatímco pro prognózu roku 2020 se procentuální ukazatele přesnosti aMAPE a WaMAPE pohybovali kolem hranice 6 % u Naivní metody a EV, u Holtovy metody ještě níže, prognóza na dvě období dopředu dosahuje odchylek aMAPE a WaMAPE v nejlepším případě 9 % a u EV nebo naivní metody až 12 %. Způsob použití metod na dvě období dopředu je podstatně méně přesný, ale stále může představovat cenné informace. Nejpresněji stále vychází Holtova metoda, která na rok 2021 předpokládá růst tržeb oproti roku 2020.

Třetí skupina přínosů práce přesahuje rámec oděvního průmyslu. Práce obsahuje všechny potřebné informace k volbě a aplikaci rozličných metod prognózy v jakékoli oblasti, kde učinění prognózy bude mít užitek. Zároveň ji lze použít i jako návod, jak změřit přesnost prognózy, který ukazatel přesnosti zvolit a co představuje. Je ale třeba zmínit, že mnou představené prognózy budou vhodnější k řešení spíše přímočarejších situací, ani jedna mnou představená metoda nezohledňuje sezónnost, která bývá častým prvkem v prognózování tržeb. Zároveň každá situace může být těžce individuální a vyžadovat ojedinělé využití metod prognózy či měření přesnosti nebo použití pokročilejších metod či určitou kombinaci metod mnou uvedených.

V mnoha případech může být dobrou volbou lineární regrese, která není závislá na čase ale na jiné proměnné, například u tržeb celého průmyslu bychom mohli hledat korelaci mezi poptávkou a určitým makroekonomickým ukazatelem. Korelace poptávky s makroekonomickými ukazateli a následnou prognózu pomocí nich jsem neudělal z důvodu, že v mých tržbách je pouze 11 zaznamenaných hodnot, které u oděvů celkem poměrně konstantně rostou a korelační koeficient by tak vyšel vyšší pro každý ukazatel, který konzistentně roste podobně jako tržby, ačkoli mezi oběma veličinami může být minimální.

Nicméně pro vyšší počet záznamů tržeb, které by nám poskytli zajímavější průběh křivky například i se sezónností by lineární regrese případně i vícefaktorová regrese byla velice dobrou metodou.

4 ZÁVĚR

Cílem mé práce bylo sestavit model prognózy poptávky v oděvním průmyslu pro rok 2020. Cíle bylo dosaženo vytvořením několika variant prognóz poptávky, jejich vzájemným porovnáním pomocí metod měření přesnosti a následným zvolením nejvhodnější metody spolu s odůvodněním a popsáním procesu výběru. V první části práce jsme si vymezily pojmy prognostiky, včetně prognostických metod a jejich funkce, dále jsme si představily metody měření přesnosti predikce.

Poptávku po výrobcích oděvního průmyslu v České republice za roky 2009 až 2019 zaznamenal ČSÚ prostřednictvím tržeb ve svém produktu *Výroba vybraných výrobků v průmyslu*, jehož data jsem upravil a vytvořil z nich reprezentativní vzorek hodnot tržeb a cen připravený k dalšímu zkoumání.

Bylo provedeno jedenáct metod a jejich variant prognózy poptávky, včetně nejprimitivnějších metod počínaje naivní metodou až po pokročilé metody zahrnující exponenciální vyhlazování s dopočtem ideálního koeficientu α a Holtovu metodu. Metody byly porovnány dle šesti metod měření přesnosti prognózy, například metodou průměrné absolutní odchylky až po vážený průměr upravené procentuální absolutní odchylky, jejíž parametry jsem musel přizpůsobit na míru datové sadě, se kterou jsem pracoval.

Nejlepších výsledků pravidelně dosahovala Holtova metoda, která využívá předností exponenciálního vyrovnávání obohacené o schopnost zohlednit trend časové řady. Dle prognózy Holtovou metodou můžeme očekávat nárůst v tržbách oděvního průmyslu o necelá 2 % a průměrný pokles ceny výrobku oděvního průmyslu o necelé 1 %. Při hodnocení výsledků metod se ale ukázali i nevýhody mnou zvoleného postupu, když jsem se rozhodl porovnat výsledky nejlepších metod pro kategorii oděvů celkem s jednoduchou lineární regresí, ukázala se možnost výskytu dilematu mezi jednou kvalitní a více méně přesnými metodami prognózy. Stejná data a metody prognózy se dají použít k predikci tržeb i na období více v budoucnu, například pro rok 2021, ale cena za tento způsob použití je prudké zhoršení v oblasti přesnosti metod.

SEZNAM POUŽITÝCH ZDROJŮ

ARMSTRONG, Jon Scott, 2002. *Principles of Forecasting: a Handbook of Researchers and Practitioners*. Kluwer Academic. s. 850, ISBN 978-0-7923-7930-0

BUDÍKOVÁ, Marie, Maria KRÁLOVÁ a Bohumil MAROŠ, 2012. *Průvodce základními statistickými metodami*. Praha: Grada, Expert (Grada). ISBN 978-80-247-3243-1.

BUŘITA, Ladislav, 2003. *Prognostické metody a jejich využití v resortu obrany*. In *Obrana a strategie č. 1/2003*. Brno: USS UO 2003. ISSN 1214-6463. s. 47-60.

GLEN, Stephanie, 2021. *Regression Analysis Step by Step*. Statisticshowto.com [online]. [cit. 2021-5-11]. Dostupné z: <https://www.statisticshowto.com/probability-and-statistics/regression-analysis>

JUREČKA, Václav, 2013. *Makroekonomie*. 2., aktualiz. vyd. Praha: Grada, Expert (Grada). ISBN 978-80-247-4386-8.

HINDLS, Richard, Stanislava HRONOVÁ, Jan SEGER a Jakub FISCHER, 2007. *Statistika pro ekonomy*. 8.vyd. Praha: Professional Publishing. 415 s. ISBN 978-80-86946-43-6.

HYNDMAN, Rob J., & ATHANASPOULOS, George, 2018. *Forecasting: principles and practice*, 2nd edition, OTexts: Melbourne, Australia. OTexts.com/fpp2. Accessed on <1/11/2020>

LEVENBACH, Hans, 2016. *Why Distinguish Forecasting Methods from Forecasting Models* [online].[cit. 2021-5-11]. Dostupné z: <https://www.linkedin.com/pulse/why-distinguish-forecasting-methods-from-models-same-levenbach-cpdf>

MAITAH, Mansoor, 2010. *Makroekonomie v praxi*. Praha: Wolters Kluwer Česká republika. ISBN 978-80-7357-560-1.

Math and Stats Support Centre. *Jednoduchá lineární regrese*. In: Slideshare [online]. [cit. 2021-1-12]. Dostupné z: <https://readgur.com/doc/2636262>.

- NOVOTNÝ, Daniel, 2013. *Analýza metod predikce poptávky v prostředí elektronického obchodu*. [online]. Praha. [cit. 2020-12-10]. Dostupné z: <https://vskp.vse.cz/44418>. Diplomová práce. Vysoká škola ekonomická v Praze
- POJKAROVÁ, Kateřina, 2006. *Ekonomie a prognostika v dopravě*. Pardubice: Univerzita Pardubice. ISBN 80-7194-868-3.
- ROWE, Gene, George WRIGHT a Fergus BOLGER, 1991. *The Delphi Technique: A Re-Evaluation of Research and Theory* [online]. 239 [cit. 2021-5-11]. Dostupné z: https://www.researchgate.net/publication/228237839_The_Delphi_Technique_A_Re-Evaluation_of_Research_and_Theory
- URBANEC, Matěj, 2015. *Kvantitativní analýza predikce poptávky u vybrané společnosti* [online]. Praha. [cit. 2020-12-10]. Dostupné z: <https://vskp.vse.cz/46503>. Diplomová práce. Vysoká škola ekonomická v Praze
- SELLAIAH, Suresh, 2017. *Statistical forecast errors*. In: blog.olivehorse.com [online]. [cit. 2021-12-5]. Dostupné z: <https://blog.olivehorse.com/statistical-forecast-errors>
- Výroba vybraných výrobků v průmyslu 2019. Český statistický úřad [online]. 30. 11. 2020 [cit. 2021-5-11]. Dostupné z: <https://www.czso.cz/csu/czso/vyroba-vybranych-vyrobku-v-prumyslu-2019>

SEZNAM TABULEK

Tabulka 1: Vliv parametru alfa na váhy pozorování	23
Tabulka 2: Vývoj tržeb a cen	30
Tabulka 3: Použité metody měření přesnosti	30
Tabulka 4: Zkoumané prognostické metody	31
Tabulka 5: Kategorie a jejich zkratky	31
Tabulka 6: Prognóza tržeb a cen pro rok 2020	36
Tabulka 7: Prognóza tržeb a cen pro rok 2020 pokročilejšími metodami	36
Tabulka 8: Přesnost prognózy naivní metodou, metodou průměru a driftovou metodou	37
Tabulka 9: Přesnost prognózy metodou klouzavého průměru a EV s $\alpha = 0,2$	38
Tabulka 10: Přesnost podle metody EV s optimálním α pro MAD, MSE a WaMAPE	39
Tabulka 11: Přesnost Holt. m. pro optimální koeficienty MAD, MSE a WaMAPE	40
Tabulka 12: Metody vykazující nejvyšší přesnost dle kategorie a ukazatele přesnosti	42
Tabulka 13: Zvolená prognóza pro rok 2020	43
Tabulka 14: Vývoj tržeb a průměrné ceny včetně prognózy pro rok 2020	43
Tabulka 15: Porovnání přesnosti a hodnoty prognózy 2020	46
Tabulka 16: Ukazatele přesnosti prognózy pro rok 2021	51

SEZNAM GRAFŮ

Graf 1: Prognóza produkce piva v Austrálii	20
Graf 2: Vývoj akcií Google z roku 2013	21
Graf 3: Členění výrobků dle množství chybějících dat	28
Graf 4: Srovnání jednoduchých metod s metodami pokročilejšími v závislosti na počtu pozorování.....	35
Graf 5: Srovnání metod prognózy tržeb oděvů celkem dle ukazatelů MAD, MSE, RMSE.....	41
Graf 6: Srovnání metod prognózy tržeb oděvů celkem dle MAPE, aMAPE, WaMAPE.....	41
Graf 7: Vývoj tržeb oděvů celkem včetně prognózy pro rok 2020.....	44
Graf 8: Křivka lineární regrese pro tržby oděvů celkem.....	45

SEZNAM OBRÁZKŮ

Obrázek 1: Rámec prognózy a plánování.....	14
Obrázek 2: Koncentrace chybějících dat.....	27
Obrázek 3: Předpoklad vhodnosti metod dle vlastností křivky	49
Obrázek 4: Druhá část předpokladu vhodnosti metod dle vlastností křivky	50

PŘÍLOHY

Příloha 1: sklatba kategorií

(Zdroj: Vlastní zpracování)

kat.	ID	Název
P	1412112002	Pracovní pánské nebo chlapecké komplety z bavlny nebo z chemických vláken
	1412113002	Pracovní pánská nebo chlapecká saka a blejzry (sportovní saka) z bavlny nebo z chemických vláken
	1412124002	Pracovní pánské nebo chlapecké kalhoty a krátké kalhoty z bavlny nebo z chemických vláken
	1412125002	Pracovní pánské nebo chlapecké náprsníkové kalhoty se šlemi z bavlny nebo z chemických vláken
	1412212002	Pracovní dámské nebo dívčí komplety z bavlny nebo z chemických vláken
	1412224002	Pracovní dámské nebo dívčí kalhoty a krátké kalhoty z bavlny nebo z chemických vláken
	1412225002	Pracovní dámské nebo dívčí náprsníkové kalhoty se šlemi z bavlny nebo z chemických vláken
	1412301302	Pracovní pánské nebo chlapecké ostatní oděvy, z bavlny nebo z chemických vláken
	1412302302	Pracovní dámské nebo dívčí ostatní oděvy, z bavlny nebo z chemických vláken
BK	1413211502	Pánské nebo chlapecké kabáty, pláště, pláštěnky atd.
	1413213002	Pánské nebo chlapecké větrovky, lyžařské bundy a podobné výrobky (jiné než saka a blejzry pletené nebo háčkované, impregnované, povrstvené, potažené, laminované nebo pogumované)
	1413132002	Dámské nebo dívčí větrovky, bundy (včetně lyžařských) a podobné výrobky, pletené nebo háčkované (kromě sak a blejzrů)
	1413311502	Dámské nebo dívčí pláště do deště a kabáty atd.
KS	1414223002	Pánské nebo chlapecké noční košile a pyžama (kromě pletených nebo háčkovaných)
	1414123002	Pánské nebo chlapecké noční košile a pyžama, pletené nebo háčkované
	1414243002	Dámské nebo dívčí noční košile a pyžama (kromě pletených nebo háčkovaných)
DŠ	1413347002	Dámské nebo dívčí šaty (kromě pletených nebo háčkovaných)
PK	1414210002	Pánské nebo chlapecké košile (kromě pletených nebo háčkovaných)
KPH	1419427002	Klobouky a jiné pokrývky hlavy, pletené nebo háčkované nebo zcela zhotovené z kraje, plsti nebo jiných textilií (ne však v pásech), sítky na vlasy z jakýchkoliv materiálů

Příloha 2A: Prognózy období 2010-2020 užitím N, pr. a drift.
(Zdroj: Vlastní zpracování)

2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Naivní										
2 165	2 380	2 398	2 356	2 522	2 513	2 892	3 214	3 650	3 431	3 507
696	762	916	870	806	859	1 058	1 065	1 428	1 293	1 352
133	87	77	64	65	70	67	79	82	78	98
111	63	47	43	48	27	32	31	31	33	34
56	70	63	54	77	71	78	76	58	57	57
51	43	40	46	44	36	51	57	60	76	66
22	18	57	52	44	44	61	76	62	64	63
475	383	397	391	420	414	441	434	463	430	468
433	313	411	365	352	348	387	308	402	326	370
1 640	1 148	1 565	1 786	1 992	1 835	1 633	1 554	2 950	3 014	2 900
341	269	269	276	293	289	294	264	324	254	256
410	393	530	373	484	524	542	553	497	479	544
289	329	346	329	389	374	444	467	449	592	611
157	169	220	216	210	223	274	295	264	276	332
Metoda průměru										
2 165	2 272	2 314	2 325	2 364	2 389	2 461	2 555	2 677	2 752	2 821
696	729	791	811	810	818	853	879	940	975	1 010
133	110	99	90	85	83	80	80	80	80	82
111	87	74	66	62	57	53	50	48	47	45
56	63	63	61	64	65	67	68	67	66	65
51	47	45	45	45	43	44	46	48	50	52
22	20	32	37	38	39	42	47	48	50	51
475	429	418	411	413	413	417	419	424	425	429
433	373	386	380	375	370	373	364	369	364	365
1 640	1 394	1 451	1 535	1 626	1 661	1 657	1 644	1 789	1 912	2 001
341	305	293	289	290	290	290	287	291	287	285
410	401	444	427	438	452	465	476	478	478	484
289	309	321	323	336	343	357	371	380	401	420
157	163	182	191	195	199	210	221	226	231	240
Driftová metoda										
2 165	2 497	2 564	2 530	2 754	2 772	3 287	3 793	4 513	4 360	4 568
696	798	1 042	1 014	938	1 010	1 296	1 346	1 929	1 811	1 961
133	72	57	43	42	43	40	48	50	47	60
111	49	32	25	27	14	15	14	14	14	14
56	79	70	58	87	82	93	91	69	67	66
51	40	35	40	39	31	44	51	56	75	67
22	16	86	89	77	81	119	163	138	149	149
475	345	349	339	366	361	387	383	413	384	423
433	270	366	321	305	297	334	259	342	275	312
1 640	976	1 384	1 671	1 976	1 859	1 650	1 558	3 219	3 514	3 540
341	240	231	233	249	245	250	222	276	214	213
410	385	575	388	517	578	614	642	580	559	642
289	352	384	368	453	443	548	599	590	821	888
157	176	256	263	261	283	367	415	378	404	507

Příloha 2B: Prognózy období 2010-2020 užitím klouz. EV 0,2 a EV MAD
(Zdroj: Vlastní zpracování)

2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
klouzávý průměr										
2 165	2 272	2 314	2 378	2 425	2 464	2 642	2 873	3 252	3 432	3 529
696	729	791	850	864	845	908	994	1 184	1 262	1 358
133	110	99	76	69	66	67	72	76	80	86
111	87	74	51	46	39	36	30	31	32	33
56	63	63	62	64	67	75	75	71	64	57
51	47	45	43	43	42	44	48	56	64	67
22	20	32	42	51	46	50	60	66	67	63
475	429	418	390	403	409	425	429	446	442	454
433	373	386	363	376	355	362	348	366	345	366
1 640	1 394	1 451	1 500	1 781	1 871	1 820	1 674	2 046	2 506	2 955
341	305	293	271	279	286	292	283	294	281	278
410	401	444	432	462	460	516	540	531	510	507
289	309	321	335	355	364	402	428	453	503	551
157	163	182	202	216	217	236	264	278	278	291
exponenciální vyhlazování - pevně dané alfa 0,2										
2 165	2 284	2 331	2 340	2 394	2 426	2 544	2 705	2 923	3 037	3 140
696	733	808	829	822	832	889	932	1 046	1 102	1 156
133	107	95	84	79	76	74	75	77	77	82
111	84	69	60	57	49	44	41	39	37	37
56	64	63	60	65	67	70	71	68	66	64
51	47	44	45	44	42	44	47	50	56	58
22	19	35	41	41	42	47	54	56	58	59
475	424	413	405	410	411	419	422	432	431	439
432,61	366,39	384,60	377,86	370,06	363,97	369,90	354,95	365,75	356,84	359,74
1 640	1 367	1 448	1 562	1 690	1 729	1 705	1 669	1 965	2 200	2 353
341	301	288	284	287	287	289	283	293	284	278
410	400	454	426	443	465	485	501	500	495	506
289	311	325	327	345	353	376	398	410	451	486
157	164	187	197	201	207	224	241	246	253	270
exponenciální vyhlazování - optimální alfa pro MAD										
2 165	2 380	2 398	2 356	2 522	2 513	2 892	3 214	3 650	3 431	3 507
696	747	870	870	824	849	998	1 046	1 318	1 300	1 337
133	87	77	64	65	70	67	79	82	78	98
111	63	47	43	48	27	32	31	31	33	34
56	67	64	57	71	71	76	76	63	59	57
51	43	40	46	44	36	51	57	60	76	66
22	18	52	52	45	44	58	73	64	64	63
475	399	397	393	414	414	435	434	456	436	461
432,61	391,92	398,37	386,88	374,85	365,55	373,00	350,72	368,11	353,74	359,31
1 640	1 148	1 565	1 786	1 992	1 835	1 633	1 554	2 950	3 014	2 900
341	270	269	275	293	289	294	265	323	256	256
410	401	452	426	442	463	481	497	497	493	503
289	329	346	329	389	374	444	467	449	592	611
157	168	216	216	211	222	270	294	266	275	328

Příloha 2C: Prognózy období 2010 – 2020 užitím EV MSE a EV WaM
(Zdroj: Vlastní zpracování)

2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
exponenciální vyhlazování - optimální alfa pro MSE										
2 165	2 380	2 398	2 356	2 522	2 513	2 892	3 214	3 650	3 431	3 507
696	755	897	874	814	854	1 034	1 062	1 384	1 304	1 346
133	87	77	64	65	70	67	79	82	78	98
111	63	47	43	48	27	32	31	31	33	34
56	66	64	58	69	70	75	75	65	61	58
51	44	41	45	44	37	49	56	60	74	67
22	18	48	51	45	45	57	71	64	64	63
475	407	400	394	411	413	431	433	452	438	458
432,61	408,76	409,17	400,28	390,54	381,95	383,04	367,97	374,71	364,97	365,99
1 640	1 148	1 565	1 786	1 992	1 835	1 633	1 554	2 950	3 014	2 900
341	269	269	276	293	289	294	264	324	254	256
410	399	464	424	448	478	503	522	512	500	516
289	328	345	330	388	374	442	466	450	588	611
157	169	220	216	210	223	274	295	264	276	332
exponenciální vyhlazování - optimální alfa pro WamAPE										
2 165	2 301	2 352	2 354	2 430	2 467	2 651	2 893	3 217	3 308	3 393
696	738	831	850	830	843	936	992	1 179	1 227	1 280
133	104	90	77	72	71	69	73	77	78	86
111	80	63	53	51	41	37	34	33	33	33
56	65	64	59	67	69	73	74	67	63	60
51	46	43	44	44	41	45	50	54	63	65
22	19	39	45	44	44	51	62	62	63	63
475	416	406	399	409	411	424	428	443	437	451
433	357	385	375	365	357	370	343	368	350	359
1 640	1 328	1 452	1 611	1 784	1 807	1 731	1 655	2 209	2 552	2 700
341	295	282	279	285	287	290	279	298	280	269
410	399	468	423	450	483	508	528	514	499	518
289	315	331	330	357	364	399	428	437	503	549
157	165	194	205	207	214	240	264	264	269	296

Příloha 2D: Prognózy období 2010-2020 užitím Holt. pro MAD, MSE a WaMAPE

(Zdroj: Vlastní zpracování)

2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Holtova metoda - optimální alfa a beta pro MAD										
2 165	2 423	2 429	2 374	2 513	2 524	2 861	3 204	3 642	3 507	3 528
696	764	897	901	857	871	1 001	1 059	1 303	1 327	1 371
133	77	75	65	66	70	67	77	81	78	94
111	47	43	41	48	27	31	31	31	33	34
56	71	64	56	71	71	76	75	64	60	58
51	40	38	45	44	35	51	60	63	80	69
22	18	42	48	47	47	53	62	63	64	65
475	392	399	400	411	413	420	422	430	428	434
433	343	370	367	363	360	364	356	362	358	359
1 640	974	1 610	1 820	2 018	1 836	1 623	1 545	3 014	3 047	2 910
341	270	278	282	289	289	291	283	295	283	279
410	397	461	431	446	466	483	497	498	495	503
289	345	363	341	404	389	460	487	468	611	638
157	170	216	224	221	229	267	295	282	285	324
Holtova metoda - optimální alfa a beta pro MSE										
2 165	2 460	2 441	2 364	2 555	2 537	2 978	3 345	3 820	3 496	3 531
696	773	931	915	849	875	1 044	1 091	1 393	1 361	1 396
133	77	71	61	63	68	67	77	82	79	96
111	54	42	39	45	29	30	31	31	32	33
56	70	63	58	67	66	69	69	66	65	64
51	42	39	44	44	37	48	56	61	74	69
22	18	45	51	49	48	56	67	67	67	67
475	382	392	393	410	412	426	428	443	435	449
433	343	370	367	363	360	364	356	362	358	359
1 640	1 014	1 578	1 773	1 959	1 830	1 655	1 577	2 774	2 903	2 852
341	274	278	282	289	289	291	284	294	285	282
410	395	472	430	452	479	501	520	515	507	519
289	339	359	342	396	389	450	482	470	594	633
157	171	221	227	222	230	272	300	282	286	329
Holtova metoda - optimální alfa a beta pro WaMAPE										
2 165	2 500	2 468	2 368	2 598	2 552	3 076	3 462	3 973	3 507	3 559
696	769	916	910	853	873	1 026	1 080	1 358	1 352	1 389
133	85	75	65	64	67	66	74	79	78	90
111	56	44	41	46	32	32	31	31	32	33
56	75	62	53	78	71	79	76	57	57	57
51	40	38	45	44	35	52	60	63	80	69
22	18	42	48	47	47	53	62	63	64	65
475	375	391	393	412	413	429	430	448	435	454
433	343	370	367	363	360	364	356	362	358	359
1 640	974	1 610	1 820	2 018	1 836	1 623	1 545	3 014	3 047	2 910
341	274	278	283	289	289	291	284	294	285	282
410	397	461	431	446	466	483	497	498	495	503
289	344	362	340	403	389	459	487	469	611	642
157	175	241	231	221	234	291	313	276	287	348

Příloha 3A: Přesnosti metod prognózy dle MAD, MAPE a aMAPE
(Zdroj: Vlastní zpracování)

	N	pr	drift	klouz	EV 0,2	EV MAD	EV MSE	EV WaM	Holt MAD	Holt MSE	Holt WaM
MAD	188 432	458 780	304 029	264 435	371 318	188 432	188 432	188 679	183 729	189 992	187 634
	114 741	211 690	209 829	138 325	176 697	107 007	110 934	107 007	99 873	103 862	100 627
	11 815	19 417	28 261	16 877	17 980	11 815	11 815	12 172	10 353	10 585	11 251
	10 106	26 551	17 376	15 667	20 264	10 106	10 106	10 765	8 208	8 968	8 647
	8 722	9 745	15 714	9 337	9 751	8 184	8 630	8 722	8 824	9 912	9 282
	7 389	10 264	9 399	7 884	9 366	7 389	7 412	7 404	7 200	7 274	7 200
	10 752	17 272	48 256	11 736	13 358	9 884	10 054	9 948	9 970	10 672	9 970
	28	30	62	31	28	24	25	25	25	26	26
	61	40	71	42	42	43	43	40	40	40	40
	335	531	448	469	488	335	335	335	344	351	344
	27	27	48	30	27	26	27	27	23	23	23
	63	62	83	58	58	58	59	63	58	59	58
	42	90	64	57	75	42	42	42	38	39	38
	26	51	59	29	59	26	26	26	24	24	24
MAPE	6,22	14,41	9,80	8,64	11,78	6,22	6,22	6,23	6,67	6,85	6,78
	10,47	18,07	19,13	12,45	15,32	9,78	10,16	9,78	10,88	11,12	10,89
	14,55	26,10	35,70	21,84	23,63	14,55	14,55	15,01	11,23	11,69	12,31
	22,82	69,23	43,41	35,86	50,56	22,82	22,82	23,78	12,62	13,85	12,40
	13,10	14,73	24,64	14,54	14,93	12,61	13,35	13,10	14,22	15,79	14,56
	14,06	18,31	17,12	14,71	16,97	14,06	14,12	14,11	14,75	14,88	14,75
	19,85	30,39	84,47	21,43	23,73	18,17	18,49	17,99	34,62	35,82	34,62
	6,71	7,15	14,71	7,47	6,83	5,86	6,08	5,89	5,72	5,87	5,94
	17,39	11,83	19,18	12,28	12,19	12,66	12,75	11,83	10,91	10,91	10,91
	17,16	23,42	22,19	22,09	22,19	17,16	17,16	17,16	22,21	22,33	22,21
	9,62	9,78	16,67	10,91	9,77	9,48	9,62	9,78	7,59	7,71	7,69
	13,52	12,48	17,80	11,75	11,83	11,79	12,09	13,52	12,63	12,72	12,63
	9,33	18,61	14,27	12,19	15,54	9,33	9,37	9,33	9,80	9,98	9,82
	10,00	19,22	23,13	11,48	15,45	9,87	10,00	9,87	10,57	10,73	10,87
aMAPE	6,49	16,05	9,06	9,29	12,86	6,49	6,49	6,52	6,37	6,54	6,47
	11,16	20,71	17,10	13,69	17,14	10,64	10,91	10,64	9,96	10,23	10,00
	13,55	22,13	42,44	19,06	20,68	13,55	13,55	13,89	11,67	12,10	12,82
	18,31	50,20	54,08	27,29	38,29	18,31	18,31	18,53	14,79	16,40	15,04
	13,24	14,94	22,37	14,28	14,95	12,61	13,29	13,24	13,60	15,22	13,99
	14,43	19,64	18,93	15,36	17,96	14,43	14,50	14,48	14,05	14,20	14,05
	23,50	37,42	62,23	26,22	29,11	21,91	22,32	22,47	22,65	23,65	22,65
	6,53	6,96	15,47	7,26	6,64	5,66	5,88	5,70	5,84	5,99	6,07
	16,92	10,97	20,80	11,61	11,42	11,78	11,58	10,97	11,00	11,00	11,00
	18,30	26,26	23,83	23,62	24,22	18,30	18,30	18,30	19,42	19,53	19,42
	9,12	9,21	17,75	10,40	9,26	8,98	9,12	9,21	7,85	7,96	7,94
	13,51	13,23	16,64	12,12	12,37	12,36	12,47	13,51	12,35	12,43	12,35
	10,01	21,23	12,92	13,23	17,31	10,01	10,05	10,01	8,99	9,17	9,00
	10,66	21,70	20,47	12,65	17,12	10,57	10,66	10,57	9,74	9,91	10,03

Příloha 3B: Přesnosti metod prognózy dle MSE, RMSE a WaMAPE
(Zdroj: Vlastní zpracování)

	N	pr	drift	klouz	EV 0,2	EV MAD	EV MSE	EV WaM	Holt MAD	Holt MSE	Holt WaM
MSE (v mil.)	56 776	328 289	209 603	124 452	214 507	56 776	56 776	58 738	57 711	48 249	56 395
	23 026	71 815	77 489	32 583	49 557	23 586	22 549	23 586	21 335	19 775	20 011
	298	587	1 004	513	506	298	298	310	281	277	293
	303	823	456	526	596	303	303	337	277	274	277
	125	111	301	117	113	112	111	125	121	113	139
	74	162	127	95	130	74	73	73	81	72	81
	239	413	3 148	278	309	232	231	250	240	230	240
MSE	1 380	1 521	4 430	1 448	1 411	1 265	1 251	1 257	1 332	1 291	1 305
	5 044	2 537	7 522	2 615	2 612	2 706	2 964	2 537	2 673	2 673	2 673
	254 588	482 959	329 013	347 739	386 591	254 588	254 588	254 588	272 704	264 408	272 704
	1 495	1 128	2 848	1 220	1 110	1 467	1 495	1 127	1 023	1 012	1 012
	6 590	5 309	10 798	4 207	4 676	4 744	4 514	6 590	4 813	4 623	4 813
	3 252	12 669	8 421	4 839	8 581	3 252	3 249	3 252	2 582	2 494	2 570
	1 041	3 335	5 180	1 450	2 218	1 067	1 041	1 067	901	894	929
RMSE	238 278	572 965	457 824	352 778	463 149	238 278	238 278	242 360	240 230	219 655	237 476
	151 743	267 984	278 368	180 507	222 613	153 576	150 162	153 576	146 065	140 625	141 461
	17 272	24 235	31 683	22 644	22 485	17 272	17 272	17 597	16 765	16 636	17 109
	17 403	28 684	21 344	22 930	24 418	17 403	17 403	18 360	16 655	16 562	16 639
	11 177	10 541	17 335	10 837	10 632	10 599	10 533	11 177	10 992	10 633	11 789
	8 597	12 728	11 287	9 741	11 410	8 597	8 533	8 544	8 983	8 509	8 982
	15 452	20 315	56 108	16 665	17 580	15 227	15 183	15 816	15 482	15 180	15 482
	37	39	67	38	38	36	35	35	36	36	36
	71	50	87	51	51	52	54	50	52	52	52
	505	695	574	590	622	505	505	505	522	514	522
	39	34	53	35	33	38	39	34	32	32	32
	81	73	104	65	68	69	67	81	69	68	69
	57	113	92	70	93	57	57	57	51	50	51
	32	58	72	38	47	33	32	33	30	30	30
WaMAPE	7,07	21,64	11,85	10,38	16,48	7,07	7,07	7,04	6,70	6,73	6,42
	11,31	26,78	20,28	14,45	20,83	10,57	10,89	10,57	9,43	9,62	9,31
	10,76	14,18	51,30	12,75	14,15	10,76	10,76	10,71	10,02	10,49	10,35
	9,89	46,36	66,77	15,27	29,84	9,89	9,89	8,69	9,05	9,77	7,72
	9,95	15,13	22,16	14,72	15,16	10,65	12,07	9,95	11,28	14,24	10,06
	15,38	25,04	21,18	17,07	21,80	15,38	15,38	15,37	15,09	15,33	15,09
	14,81	32,95	66,44	16,48	21,67	13,70	13,70	12,97	12,87	14,77	12,87
	5,68	5,58	14,68	5,26	5,11	4,76	4,73	4,69	4,90	4,84	4,81
	16,08	8,70	20,22	10,19	9,36	10,17	9,60	8,70	8,60	8,60	8,60
	15,49	31,15	20,83	25,25	27,07	15,49	15,49	15,49	15,53	15,90	15,53
	9,80	8,68	17,44	9,59	8,85	9,54	9,80	8,67	8,52	8,52	8,51
	10,12	11,37	14,21	10,35	10,00	9,98	10,13	10,12	9,79	9,86	9,79
	10,49	28,01	15,31	15,38	21,98	10,49	10,58	10,49	9,08	9,51	9,09
	10,94	24,83	23,79	11,32	18,25	10,90	10,94	10,90	9,66	9,72	9,22